



Ramiro Manuel Maurício Morais

Licenciado em Ciências da Engenharia Electrotécnica e de Computadores

Plataforma de previsão do consumo elétrico para edifícios inteligentes

Dissertação para obtenção do Grau de Mestre em Engenharia Electrotécnica e de Computadores

Orientadores: João Francisco Alves Martins, Professor Auxiliar, Universidade Nova de Lisboa
José Alberto Oliveira Lima, Mestre, Universidade Nova de Lisboa

Júri:

Presidente: Doutor João Miguel Murta Pina
Arguente: Doutor Yves Philippe Rybarczyk
Vogais: Doutor João Francisco Alves Martins
Mestre José Alberto Oliveira Lima



FACULDADE DE
CIÊNCIAS E TECNOLOGIA
UNIVERSIDADE NOVA DE LISBOA

Dezembro 2013

Plataforma de previsão do consumo elétrico para edifícios inteligentes

Copyright © Ramiro Manuel Maurício Morais, Faculdade de Ciências e Tecnologia,
Universidade Nova de Lisboa

A Faculdade de Ciências e Tecnologia e a Universidade Nova de Lisboa têm o direito, perpétuo e sem limites geográficos, de arquivar e publicar esta dissertação através de exemplares impressos reproduzidos em papel ou de forma digital, ou por qualquer outro meio conhecido ou que venha a ser inventado, e de a divulgar através de repositórios científicos e de admitir a sua cópia e distribuição com objetivos educacionais ou de investigação, não comerciais, desde que seja dado crédito ao autor e editor.

Aos meus pais.

Agradecimentos

Em primeiro lugar, aos meus pais, por todo o apoio que me deram e por me terem dado a possibilidade de terminar esta fase complicada e importante da minha vida.

Ao meu orientador, Professor João Martins, pela orientação do trabalho e por toda a simpatia e disponibilidade não só neste trabalho, mas ao longo do meu percurso universitário.

Ao meu coorientador, José Lima, pela ajuda, aconselhamentos e amizade que me deu, e pelas horas despendidas a alinhar os lasers e a soldar fios.

A todos aqueles que direta ou indiretamente contribuíram para a realização deste trabalho, seja pelas sugestões ou pela força de vontade que me deram.

Por fim, aos meus “Bazingas”, como não podia deixar de ser, são os maiores.

Resumo

O consumo energético de um edifício depende de vários fatores, realçando-se a sua ocupação, as condições climáticas, as características e localização do edifício, ou mesmo o preço da eletricidade como os mais importantes. A otimização deste consumo deve passar pela monitorização e previsão desses fatores. Desta forma, previsões e análises fiáveis de perfis de ocupação são necessárias. No entanto, uma grande parte dos edifícios existentes não tem sistemas dedicados de monitorização da sua ocupação, devido à sua idade ou limitações monetárias.

Este trabalho pretende avaliar a possibilidade de fazer uma previsão a curto-prazo do consumo elétrico de um edifício, através dos dados relativos à lotação do parque de estacionamento e do histórico do consumo elétrico do mesmo, correlacionando assim dois tipos de dados com uma relação pouco direta. Pretende também avaliar a potencialidade destes dados serem usados como forma indireta de representar a ocupação do edifício.

De forma a melhorar a correlação entre os dados da lotação do parque e o consumo elétrico, foi desenvolvido um módulo de utilização temporária, para determinar a ocupação do edifício em questão, gerando *a posteriori* um perfil de ocupação de forma a relacioná-lo com o número de carros no parque. Esse perfil foi depois inserido como entrada de uma Rede Neuronal Artificial, com a finalidade de prever o consumo elétrico a curto-prazo, face ao consumo real correspondente. O módulo adquiriu dados durante 8 semanas, sendo que, a partir destes, foram extrapolados os valores para 9 meses. Estes dados foram utilizados para a previsão do consumo elétrico, no mesmo período. Os resultados da previsão da RNA apresentaram um perfil de consumo elétrico semelhante ao real e valores de teste médios de MSE na ordem de 6×10^{-9} com uma correlação média de 1. Destes resultados, poder-se-á concluir que a lotação do parque de estacionamento associado ao edifício em estudo pode ser utilizada como parâmetro de previsão de consumo elétrico do edifício, na medida em que o perfil obtido por previsão é bastante idêntico ao real, o erro de previsão é muito reduzido e a correlação entre os valores previstos e os registados é muito elevada. No entanto, deve salientar-se que a ocupação não mostrou uma influência no consumo elétrico do edifício tão grande como o sistema de AVAC, mas não deve ser desprezada em previsões de consumo elétrico.

Palavras-chave: previsão do consumo elétrico; redes neuronais artificiais; ocupação de edifícios; parque de estacionamento

Abstract

The electric load of a building depends on multiple factors like occupancy, climate conditions, the building location and characteristics or even the price of electricity are the most important. The optimization of this load should encompass the monitoring and forecasting of these factors. Therefore, accurate occupancy profile forecasting and analysis are required. However, most buildings don't have dedicated systems for monitoring occupancy, due to their age or budget constraints.

The present study intends to evaluate the possibility of a short-term electric load forecasting of a building, using the parking lot occupancy data and the electrical load historic data, correlating two types of data apparently not relatable. Also, this study intends to evaluate the potential of this data to be used as a load forecasting parameter, as an indirect value for building occupancy representation.

In order to improve the correlation between the parking lot occupancy and the electric load, a module was developed to be used temporarily, with the goal of determining the building's occupancy, generating afterwards an occupancy profile, in order to relate it with the number of cars in the park. This profile was later on used as an input in an Artificial Neural Network, to forecast the short-term electric load of the same building and compare it with the actual electric load. The module has acquired data throughout 8 weeks, which have been used to extrapolate the values of occupancy for 9 months. This data was used for forecasting the electric load, also for the same period. The obtained ANN forecasts revealed an electric load profile similar to the actual one, the average tests' MSE of approximately 6×10^{-9} and an average correlation of 1. From these results, it is concluded that the studied building's parking lot occupancy can be used as a parameter for electric load forecasting regarding the same building, as the electric load profile is identical to the actual one, the forecasting error obtained is very low and the correlation is very high. However, it should be pointed out that although the influence of the occupancy proved to be smaller than the HVAC system's in the present study, it should not be disregarded for electric load forecasting.

Keywords: Electric load forecasting; artificial neural networks; building occupancy; parking lot

Índice de matérias

1	Introdução	1
1.1	Motivação	1
1.2	Objetivos	3
1.3	Estrutura do documento	4
2	Previsão do consumo energético	5
2.1	Fatores inerentes ao consumo energético	5
2.1.1	Clima	5
2.1.2	Características do edifício	6
2.1.3	Sistemas de consumo energético direto	7
2.1.4	Fatores económicos	8
2.1.5	Características de utilização do edifício	8
2.2	Modelos para previsão de consumo energético	9
2.2.1	Modelos estatísticos	9
2.2.2	Modelos de inteligência artificial	11
2.3	Ocupação de edifícios	15
2.3.1	Perfil de ocupação	15
2.3.2	Métodos para determinação da ocupação	17
3	Solução proposta	19
3.1	Caracterização do parque de estacionamento e do edifício	19
3.2	Aquisição de dados	21
3.2.1	Dados relativos à ocupação do edifício em questão	21
3.2.2	Dados relativos à lotação do parque de estacionamento do recinto.	21
3.2.3	Dados relativos ao consumo elétrico real do edifício em questão	21
3.3	Processamento dos dados	22
3.3.1	Determinação da relação entre a lotação do parque de estacionamento e a ocupação do edifício.	22
3.3.2	Determinação da relação entre a lotação do parque e o consumo elétrico do edifício.	22
4	Implementação	23
4.1	Módulo para determinar a ocupação do edifício	23
4.2	Medidor de consumo elétrico	31
4.3	Processamento de dados e extrapolações	32
5	Resultados e discussão	33
5.1	Ocupação do edifício	33
5.2	Lotação do parque de estacionamento	35
5.3	Extrapolação dos valores de ocupação para 9 meses	37
5.4	Previsão do consumo elétrico do edifício	41
5.4.1	Previsão com o conjunto de dados completo	41
5.4.2	Previsão sem os dados do sistema A V A C	43
5.4.3	Previsão sem os dados da ocupação do edifício	44

5.4.4 Comparação entre as previsões sem os dados do sistema AVAC e sem os dados da ocupação do edifício	46
6 Conclusões e trabalho futuro	47
Referências	49

Índice de figuras

<i>Figura 2.1 - Neurónio artificial (Modificado de Kalogirou & Bojic [49]) – as entradas x_n são multiplicadas pelo fator específico resultando nos W_n. De seguida, são somados e passados pela função de ativação, resultando nas saídas.</i>	12
<i>Figura 2.2 - Layers de uma RNN do tipo Single Perceptron.</i>	13
<i>Figura 2.3 - Perfis de ocupação de dias úteis e fins-de-semana para o edifício de administração (retirado de Davis III & Nutter [58]).</i>	16
<i>Figura 2.4 - Perfis de ocupação de dia úteis e fins-de-semana para a biblioteca (retirado de Davis III & Nutter [58]).</i>	16
<i>Figura 2.5 - Rede de sensores e sua interligação para previsão de consumo elétrico, considerada por Ekwevugbe et al. [59].</i>	17
<i>Figura 3.1 - Mapa do campus da Faculdade de Ciências e Tecnologia. As entradas são efetuadas pelas portarias P1 a P7 e contabilizadas [61].</i>	20
<i>Figura 4.1 - Arduino Duemilanove.</i>	23
<i>Figura 4.2 - Modo de funcionamento dos sensores ultrassónicos, à passagem de uma pessoa.</i>	25
<i>Figura 4.3 - Esquema de funcionamento dos lasers e resistências, à passagem de uma pessoa.</i>	26
<i>Figura 4.4 - Máquina de estados dos processos de entrada/saída.</i>	27
<i>Figura 4.5 – Interface da aplicação desenvolvida para gravação dos dados e monitorização do sistema.</i>	28
<i>Figura 4.6 - Esquema de ligações elétricas do módulo de ocupação utilizado.</i>	28
<i>Figura 4.7 - Caixa onde foi colocado o Arduino, após a sua instalação no edifício.</i>	29
<i>Figura 4.8 - Caixa que contém os emissores laser, após instalação no edifício.</i>	29
<i>Figura 4.9 - Caixa que contém as resistências LDR (em baixo) e a caixa com o Arduino (em cima).</i>	30
<i>Figura 4.10 - Módulo para determinar a ocupação, após a sua instalação.</i>	30
<i>Figura 4.11 - Esquema da arquitetura do sistema de análise de consumo elétrico do edifício e do sistema AVAC.</i>	31
<i>Figura 4.12 - Visão geral de toda a rede de dados utilizada no trabalho.</i>	32
<i>Figura 4.13 - Ferramenta Neural Network Toolbox™ do ambiente de simulação Matlab.</i>	32
<i>Figura 5.1 - Perfil de ocupação do edifício para 8 semanas. Os “Q” a vermelho representam as quintas-feiras.</i>	33
<i>Figura 5.2 - Perfil de ocupação semanal médio do edifício. No eixo das abcissas estão assinaladas a vermelho as 12h de cada dia.</i>	35
<i>Figura 5.3 - Lotação do parque (a laranja) vs ocupação do edifício (a azul) vs pessoas por carro (a roxo).</i>	36
<i>Figura 5.4- Configuração da RNA utilizada para criar um perfil geral de pessoas por carro.</i>	38
<i>Figura 5.5 - Resultado da simulação em Matlab com RNA do perfil de pessoas por carro. A previsão está representada a azul e os valores registados a laranja.</i>	38
<i>Figura 5.6 - Perfil de ocupação real (a cinzento) vs previsto (a amarelo).</i>	40
<i>Figura 5.7 - Configuração da RNA utilizada para efetuar a previsão do consumo elétrico do edifício para 9 meses.</i>	41
<i>Figura 5.8 - Resultado da RNA da previsão do consumo elétrico do edifício, com o consumo real (roxo) vs consumo previsto com os dados do AVAC e da ocupação (laranja).</i>	42
<i>Figura 5.9 - Resultado da RNA da previsão do consumo elétrico do edifício, com o consumo previsto sem os dados do AVAC (roxo) vs consumo previsto com os dados do AVAC (verde).</i>	43
<i>Figura 5.10 - Resultado da RNA da previsão do consumo elétrico do edifício, com o consumo previsto com os dados do AVAC (verde) vs o consumo previsto sem os dados da ocupação do edifício (laranja).</i>	44
<i>Figura 5.11 - Resultado da RNA da previsão do consumo elétrico do edifício, com o consumo sem os dados do AVAC (roxo) vs consumo previsto sem os dados da ocupação (laranja).</i>	46

Índice de tabelas

<i>Tabela 2.1 - Lista de métodos recomendados e suas aplicações (adaptado de Yan et al. [55]).</i>	14
<i>Tabela 5.1 - Resultados de MSE e correlações das 5 simulações realizadas, com dados de 8 semanas.</i>	39
<i>Tabela 5.2 - Resultados de MSE e correlações das 5 simulações realizadas, com dados de 6 semanas.</i>	40
<i>Tabela 5.3 - Resultados de MSE e correlações das 5 simulações realizadas da RNA para 9 meses, com dados do AVAC incluídos.</i>	42
<i>Tabela 5.4 - Resultados de MSE e correlações das 5 simulações realizadas da RNA para 9 meses, sem dados do AVAC.</i>	44
<i>Tabela 5.5 - Resultados de MSE e correlações das 5 simulações realizadas da RNA para 9 meses, sem dados da ocupação do edifício.</i>	45

Lista de abreviaturas

RNA - Rede Neuronal Artificial

AVAC - Aquecimento, Ventilação e Ar Condicionado

PCE - Previsão do consumo energético

ARMA - *AutoRegressive Moving Average*

ARIMA - *AutoRegressive Integrated Moving Average*

MVS - Máquinas de Vetores de Suporte

RFID - *Radio-Frequency Identification*

QGBT - Quadro Geral de Baixa Tensão

LDR - *Light Dependent Resistor*

RTC - *Real Time Clock*

MSE - *Mean Squared Error*

1 Introdução

Anualmente, os edifícios são responsáveis por, aproximadamente, 40% do consumo energético a um nível global [1], [2], tendo um forte impacto na produção de CO₂, devido aos combustíveis fósseis que são utilizados para a produção de energia, excedendo mesmo a produção de CO₂ totalizada por todos os meios de transporte [3]. Por isso, é imperativo encontrar soluções para reduzir esse impacto, diminuindo de igual forma os custos e a pegada ecológica dos mesmos. Com essa preocupação, a União Europeia tem emitido diretivas para os seus estados membros, que visam implementar medidas para reduzir esse impacto, através de requisitos de performance energética nos edifícios, a última das quais é a Diretiva n.º 2010/31/UE, de 19 de maio de 2010, do Parlamento Europeu e do Conselho que foi transposta para a legislação portuguesa pelo Decreto-Lei n.º 118/2013, publicado no Diário da República, 1.ª série, N.º 159, de 20 de agosto de 2013 [4]. Deste modo, pretende-se melhorar a eficiência energética dos edifícios nacionais, tanto dos novos como dos recuperados.

1.1 Motivação

A eficiência energética de um edifício depende de uma miríade de fatores, como as condições climáticas, as características de construção do edifício e utilização a que se destina, a ocupação do mesmo e os sistemas que providenciam melhoria no conforto dos ocupantes. Devido à grande diversidade de edifícios e dos fins a que se destinam, desde habitação, comércio ou indústria, aos serviços públicos como os hospitais, serviços de urgência e universidades, há uma enorme necessidade de planeamento do consumo energético, visando uma otimização tanto a nível de sustentabilidade como a nível económico. Esta otimização deve estar incluída no projeto de novos edifícios, pois a alteração dos já existentes envolve processos burocráticos complicados e dispendiosos [5], [6].

Dada a complexidade em avaliar a influência de cada um dos fatores individuais acima indicados que afetam o consumo energético de um edifício, é um desafio obter-se uma previsão com boa exatidão [7]. Assim, e nesse sentido, existem diversos métodos, de complexidades diferentes, procurando abranger o maior número de diferentes problemas [8].

Um dos fatores com maior influência no consumo energético de um edifício diz respeito à ocupação do mesmo e às atividades que ocorrem no seu espaço [9]. Diversas vezes, a previsão do número de ocupantes baseia-se mais em modelos e expectativas do que em registos de contagens efetivas, levando a grandes disparidades entre os consumos energéticos previstos e os

reais [10]. No entanto, nem sempre há possibilidade de determinar o número real de ocupantes, devido a sistemas de contagem pouco eficientes ou devido a fatores económicos que tornam bons sistemas de contagem muito dispendiosos. Assim, será vantajoso encontrar outras formas de se obterem contagens de ocupantes indiretamente, por exemplo [11]. Uma dessas formas poderá ser através da lotação de parques de estacionamento associados ao edifício.

Na literatura, não existem trabalhos que abordem a determinação da ocupação através da lotação de um parque de estacionamento. Pretende-se assim, com este trabalho, estudar a possibilidade de prever o consumo elétrico de um edifício, tendo por base a lotação do parque de estacionamento, relacionando-a inicialmente com o número de ocupantes do edifício, e, caso se correlacionem, utilizar a lotação diretamente como fator de previsão de consumo elétrico do edifício.

1.2 Objetivos

O presente trabalho pretende desenvolver um método que permita efetuar previsões do consumo elétrico de um edifício para qualquer período de tempo com base em dados históricos do consumo elétrico, bem como dados de ocupação do mesmo. Pretende-se também avaliar a lotação do parque de estacionamento de uma instituição, como forma indireta de representar a ocupação de um edifício da mesma instituição e o seu consumo energético, em particular o consumo elétrico e a sua potencialidade como parâmetro de previsão de consumo para um determinado período de tempo. Nesse sentido, implementaram-se um conjunto de soluções que permitem:

- Encontrar um método de previsão de consumo elétrico.
- Determinar a ocupação do edifício em tempo real.
- Criar um perfil do número de pessoas por carro no parque da instituição, com base na ocupação real do edifício e na lotação do parque, usando uma Rede Neuronal Artificial (RNA).
- Prever o valor de consumo elétrico do edifício, usando uma RNA, com base nos dados referidos nos dois pontos anteriores e no histórico de consumo elétrico para o mesmo período temporal.
- Determinar a potencialidade das soluções estudadas, tendo em vista a previsão do consumo elétrico a curto-prazo do edifício, a partir da lotação do parque de estacionamento.

De modo a alcançar os objetivos propostos, desenvolveu-se um módulo de utilização temporária que foi instalado no edifício de forma a determinar o perfil de ocupação do mesmo. Para determinar o consumo elétrico do edifício utilizou-se um sistema de análise de consumo elétrico já implementado.

1.3 Estrutura do documento

Este trabalho encontra-se estruturado em 6 capítulos:

1. INTRODUÇÃO – Motivação, Objetivos e Estrutura do documento
2. PREVISÃO DO CONSUMO ENERGÉTICO – Descrevem-se os fatores que influenciam o consumo energético de edifícios, em especial a sua ocupação. São também apresentados diversos modelos para a previsão do consumo energético em edifícios.
3. SOLUÇÃO PROPOSTA – É apresentada a solução que se pretende implementar para determinar o consumo elétrico.
4. IMPLEMENTAÇÃO – São descritos os passos efetuados na realização do projeto.
5. RESULTADOS E DISCUSSÃO – São apresentados e comentados os resultados obtidos.
6. CONCLUSÕES E PERSPETIVAS FUTURAS – É feita uma síntese e apresentam-se ideias para trabalho futuro.

2 Previsão do consumo energético

Para realizar uma previsão do consumo energético para um determinado edifício, é necessário perceber quais os fatores que o afetam e de que forma o influenciam. Diversos estudos foram feitos sobre esses fatores e sobre os métodos que podem ser usados [9], [12], [13], [14], [15], [16], [17].

2.1 Fatores inerentes ao consumo energético

O consumo energético de um edifício depende de uma diversidade de fatores, como seja o clima, as características do edifício (e.g. materiais usados na sua construção), sistemas de consumo direto (e.g. ar condicionado, aquecimento de água), fatores económicos (e.g. preço da eletricidade) e características de utilização do edifício (e.g. ocupação).

2.1.1 Clima

Existem sete variáveis climáticas com maior importância [18] que afetam diretamente as características térmicas de um edifício, levando indiretamente a uma influência no consumo energético devido à necessidade de aquecimento/arrefecimento do edifício. As variáveis climáticas são descritas de seguida.

Dry-bulb temperature – refere-se à temperatura ambiente, indicada por um termómetro de mercúrio, não afetado pela humidade. É a temperatura mais vulgarmente utilizada e referida e serve como medida do nível de conforto térmico dos ocupantes de um edifício [16], [19]. Uma variação na temperatura ambiente que o torne desconfortável pode levar ao aumento do consumo energético do edifício, para compensar esse desconforto.

Wet-bulb temperature – diz respeito à temperatura, medida por um termómetro de mercúrio, coberto por um pano húmido de algodão [20]. A diferença entre o valor de *wet-bulb temperature* e *dry-bulb temperature* permite medir a humidade relativa. Jaber & Ajib [21] referem que a humidade relativa está relacionada com a eficiência dos sistemas de Aquecimento, Ventilação e Ar Condicionado (AVAC) e, consequentemente, com o consumo energético do edifício do qual façam parte estes sistemas.

Precipitação – Simulações demonstraram que a chuva causa um aumento significativo da humidade relativa dentro de edifícios e leva ao consequente aumento do consumo energético para aquecimento [22].

Radiação solar – É um indicador do calor armazenado nas paredes exteriores de um edifício, devido à incidência dos raios solares [23]. Tem uma influência crucial no consumo dos sistemas de arrefecimento, devido à necessidade de arrefecimento causada pelo aquecimento das paredes exteriores e consequente propagação de calor para o interior do edifício [5].

Níveis de nebulosidade e clareza do céu – São representativos da atenuação da radiação solar durante o dia e das perdas de calor à noite. Li & Lam [24] aprofundam os efeitos destes dois fatores no consumo energético de edifícios, referindo as implicações que têm na capacidade necessária dos sistemas de ar condicionado para manter o nível de conforto do edifício.

Velocidade do vento – A velocidade do vento tem influência na temperatura das paredes e consequentemente no funcionamento dos sistemas de climatização [5], [25]. A sua influência no consumo energético passa também pela capacidade de produção energética de turbinas eólicas, caso existam no edifício, que irão alterar o saldo energético do edifício requerido à rede [26].

De todas as variáveis climatéricas aqui referidas, aponta-se a *dry bulb temperature* como sendo a mais influente no consumo energético e, consequentemente, a de maior importância para a eficiência energética de edifícios [27], [28].

2.1.2 Características do edifício

Existe uma forte relação entre o formato da estrutura do edifício e o seu consumo energético. Uma redução importante pode ser conseguida através de uma boa conceção da geometria da estrutura [29]. Existe também uma influência da inércia térmica do edifício no consumo energético, isto é, o tempo de resposta às variações de temperatura exterior. As transferências térmicas entre o ambiente e o edifício podem ocorrer por condução através da estrutura do edifício, como sejam o aquecimento/arrefecimento e infiltrações de humidade, levando os ocupantes a aumentar a temperatura interior, o que aumenta por sua vez as perdas por condução [30]. Essas perdas levam à necessidade de maior isolamento. No entanto, Kim & Moon [31] verificaram que os benefícios de isolamento da estrutura do edifício são uma função exponencial inversa, implicando que quanto maior o nível de isolamento, menor o ganho que se

obtém do mesmo. Apesar disso, um dos requisitos principais para edifícios é o planeamento correto do isolamento térmico da estrutura do mesmo, permitindo uma poupança energética significativa [30].

2.1.3 Sistemas de consumo energético direto

Por sistemas de consumo energético direto entendam-se os sistemas que fazem parte do edifício e que consomem energia devido ao seu funcionamento, tendo em vista proporcionar uma melhor qualidade de vida no interior do edifício. Sistemas AVAC, caldeiras elétricas, sistemas de refrigeração e iluminação são exemplos deste tipo de sistemas. O *Smart-Accelerate Project* [32] descreve as implicações diretas no consumo energético devido a esses sistemas, que afetam o conforto térmico e visual em edifícios e a qualidade do ar no seu interior.

Destes tipos de sistemas, estima-se que os sistemas AVAC tenham um peso de 11% do consumo elétrico total em Espanha [33] e que, na China, atinjam uma parcela de 65% [34]. O seu consumo energético, além do necessário ao seu funcionamento, é influenciado pela temperatura ambiente exterior [11], [19]. Kermanshahi & Iwamiya [35] afirmam que no Japão, em horas de plena carga, um aumento de 1°C na temperatura exterior implica um aumento do consumo elétrico em cerca de 4500MW, devido à necessidade adicional de arrefecimento.

Por tudo isto, considera-se que o funcionamento dos sistemas de consumo direto de energia, em especial os sistemas AVAC, tem um peso elevado no consumo energético total de um edifício.

2.1.4 Fatores económicos

Existem diversos fatores económicos que podem influenciar o consumo energético. O preço do gás, petróleo ou outros combustíveis essenciais à produção de eletricidade podem ser fatores determinantes do seu preço e consequentes despesas do consumo pelos edifícios. É especialmente importante para as companhias da área de energia, pois segundo Pai & Hong [36], um aumento de 1% no erro de previsão implica custos de operação superiores de 10 milhões de libras. Assim, é um fator a ter em conta em planos de contenção de despesas, que poderá levar os consumidores a reduzir o consumo energético. Zavala et al. [37] fizeram um estudo sobre o impacto económico das previsões de consumo energético (PCE), demonstrando que é possível obter reduções significativas de custos ao utilizar estratégias de otimização em tempo real, antecipando as condições climáticas.

2.1.5 Características de utilização do edifício

O modo como o edifício é utilizado tem impacto fundamental no seu consumo energético. Sejam edifícios residenciais, administrativos, industriais ou comerciais, todos terão perfis de consumo energético diferentes, devidos à sua utilização, pelo fim a que são destinados. Além disso, a forma como os ocupantes utilizam os diferentes sistemas de consumo direto tem influências no consumo energético, na medida em que é um fator aleatório. A abertura ou fecho de janelas, a regulação de parâmetros de funcionamento do sistema AVAC e sistemas de iluminação são alguns exemplos de fatores aleatórios causados pela utilização do edifício [38]. Oldewurtel et al. [9] concluiu que é possível obter poupanças de 34 a 50% através de um sistema de automação de AVAC, iluminação e cortinas.

Para além do tipo de atividades a que se destina o edifício, o número de ocupantes que nele se encontram em determinado momento influencia esse consumo. Al-Mumin et al. [39] fizeram um estudo sobre a ocupação de edifícios residenciais no Kuwait, do qual se concluiu que o estilo de vida dos ocupantes influencia o consumo energético anual do edifício. O facto de muitos trabalhadores de empresas ou fábricas não estarem em casa durante o dia leva a perfis de ocupação opostos entre as residências e os locais de trabalho. Por isso, o tipo de dia (feriados, dias úteis, fim-de-semana) e a hora do dia têm também influência no consumo energético, pelo que devem ser considerados em estudos sobre o assunto, como variáveis determinísticas.

2.2 Modelos para previsão de consumo energético

Existe uma variedade de modelos estatísticos e de inteligência artificial que podem ser usados para a PCE de um edifício. Feinberg & Genethliou [13] e Alfares & Nazeeruddin [40] apresentam os principais modelos. A PCE pode ser dividida em duas categorias: curto/médio prazo e longo prazo. Consideram-se previsões de curto/médio prazo as previsões para um período temporal de até um ano. Para períodos de tempo superiores a um ano, são consideradas de longo prazo. Devido à pouca precisão das previsões de longo prazo e pelo facto de não se enquadrarem no âmbito deste trabalho, não serão aprofundadas.

As previsões a curto/médio prazo permitem criar um perfil de consumo energético, possibilitando uma visão do que pode ser feito para otimizar a gestão energética de um edifício. Com base nesse perfil, poderão ser estudadas as alterações a adotar para racionalizar os consumos energéticos ou poderá ser renegociado o contrato com o fornecedor de energia, permitindo assim reduzir os custos ao consumidor.

Os principais modelos utilizados em previsões a curto/médio prazo na atualidade são apresentados de seguida.

2.2.1 Modelos estatísticos

Dias similares

O método dos dias similares, baseia-se na procura de características semelhantes ao dia relativo à previsão, ou seja, características como as condições climáticas, ocupação do edifício, dia da semana e data [13]. Através de extrapolação com médias de valores dos dias similares, obtém-se a previsão para o dia pretendido. Esta, pode ser feita com base não só num dia similar, mas também numa combinação linear ou regressão de dias similares ao da previsão.

Como a comparação é efetuada entre o consumo de dois dias similares e esta se irá enquadrar num intervalo (para serem considerados similares), pode acontecer a seleção de dias com similaridade inferior, o que resultará num erro de previsão elevado [41]. Para reduzir esse erro, deve ser feita uma classificação ordenada de dias com maior similaridade antes de ser feita a seleção.

Regressões

Os modelos de regressão são os métodos estatísticos mais utilizados [13]. Consistem na representação de conjuntos de dados através de funções matemáticas. Estas funções tanto podem ser lineares como quadráticas, cúbicas, etc.

Os modelos de regressão podem ser utilizados para a PCE, relacionando-o com as variáveis que o influenciam, descritas no ponto 2.1. Neste sentido, Engle et al. [42] apresentam vários modelos de regressão para previsões do dia seguinte, que incorporam variáveis determinísticas como feriados, variáveis aleatórias como consumo médio e variáveis externas como as condições climáticas.

Séries temporais (ARMA e ARIMA)

As séries temporais baseiam-se em assumir-se que os dados têm uma estrutura interna, como seja uma auto-correlação, tendência ou variação sazonal, definidos por padrões periódicos [43]. Estes métodos procuram identificar esses padrões, podendo ser horários, diários, semanais ou mensais, etc.

Existem dois tipos principais de séries temporais: ARMA (*AutoRegressive Moving Average*) e ARIMA (*AutoRegressive Integrated Moving Average*), sendo que o segundo é uma extensão do primeiro, tornando processos não-estacionários em estacionários através de processos de diferenciação.

2.2.2 Modelos de inteligência artificial

Sistemas Periciais (*Expert Systems*)

Um sistema pericial é qualquer sistema artificial que tenha a capacidade de raciocinar, explicar e adquirir conhecimento à medida que mais informação é disponibilizada [40], [44]. Tem como finalidade resolver problemas complexos, funcionando com uma base de conhecimento, representada por factos e regras. Esses factos e regras são implementados por um programador humano e servem de base para as previsões. Apesar de poderem funcionar autonomamente, a qualidade das previsões está diretamente relacionada com o programador humano [45].

Máquinas de Vetores de Suporte (*Support Vector Machines*)

As Máquinas de Vetores de Suporte (MVS) são uma técnica fundamentada de *Machine Learning*, originalmente utilizadas para reconhecimento de padrões [36], são atualmente utilizados para resolver problemas de regressões não-lineares e classificação. Funcionam através do mapeamento não-linear, através das funções chamadas *kernel*. Uma vez mapeados os dados em categorias, os novos dados serão enquadrados nessas categorias, reduzindo a imprecisão do conjunto de dados iniciais. A principal dificuldade na utilização de MVS é a seleção de uma função *kernel* que corresponda a um conjunto de pontos num intervalo de classificação.

Lógica difusa (*Fuzzy Logic*)

Os modelos de lógica difusa estabelecem uma correspondência entre um conjunto de variáveis de entrada e um conjunto de variáveis de saída. Proporcionam uma forma de representar informação vaga e subjetiva. São especialmente utilizados em casos em que os dados históricos não são valores numéricos mas sim variáveis linguísticas [46]. Como exemplo, tem-se uma variável “temperatura” cujos valores sejam “frio”, “temperado” e “quente”. De facto, um modelo de lógica difusa aplicado à PCE pode ser inteiramente baseado em regras “se” – “então”. Como exemplo, tem-se a regra “Se frio, o consumo é elevado”. Estas variáveis linguísticas são especialmente utilizadas quando descrevem sistemas de conforto. Aggarwal et al. [47] utilizaram lógica difusa para efetuar uma PCE a curto-prazo, obtendo resultados melhores que um método convencional (não especificado).

Redes Neurais Artificiais

As RNA, tendo o seu desenvolvimento sido inspirado pelo funcionamento do cérebro humano, funcionam através do conceito de neurónios artificiais. Um neurónio artificial é um modelo computacional, que consiste de entradas (que, como as sinapses dos neurónios reais, realizam a ligação entre neurónios, permitindo passar a informação ao neurónio seguinte) que são multiplicadas por fatores específicos e independentes. O resultado desses produtos individuais é somado e passado por uma função de ativação, obtendo-se assim a ativação do neurónio. Cada uma das saídas do neurónio é transferida ao neurónio seguinte [48], [49], [50]. As RNA combinam os neurónios artificiais em cadeia para processar a informação. Na Figura 2.1 está representado o esquema de um neurónio artificial.




Figura 2.1 - Neurónio artificial (Modificado de Kalogirou & Bojic [49]) – as entradas x_n são multiplicadas pelo fator específico resultando nos W_n . De seguida, são somados e passados pela função de ativação, resultando nas saídas.

Os neurónios da rede são dispostos em camadas (*layers*). Existe uma *layer* de entradas, que contém os dados que se pretendem relacionar, uma *layer* de saídas com o resultado e uma ou mais *layers* ocultas (Figura 2.2). Esta arquitetura denomina-se por *Perceptron*, podendo ser *Single* ou *Multilayer* de acordo com o número de *layers* na rede.

O conhecimento da rede é adquirido através de um processo de aprendizagem/treino da mesma, em que os fatores referidos anteriormente são ajustados por iterações e armazenados. Os principais processos de aprendizagem são *feedforward* e *backpropagation*, sendo que podem ser ambos utilizados na mesma rede, sequencialmente.

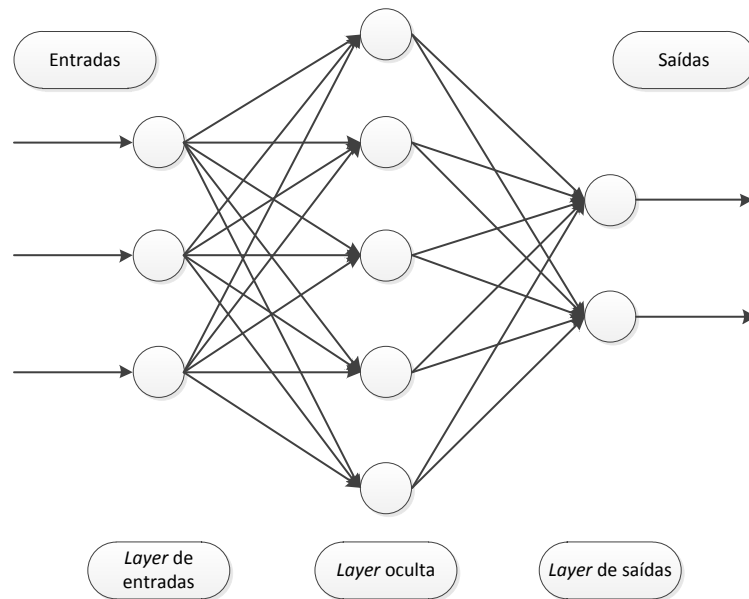


Figura 2.2 - Layers de uma RNN do tipo *Single Perceptron*.

Feedforward

Nos algoritmos *feedforward*, a *layer* de entrada passa a ativação dos neurónios à *layer* seguinte e assim sucessivamente até à *layer* de saída. É o método mais simples de treino de uma rede neuronal.

Backpropagation

O método de treino de redes neuronais conhecido por *backpropagation* escolhe um vetor de treino a partir de um conjunto de dados e desloca-o da *layer* de entrada em direção à *layer* de saída. Na *layer* de saída o erro é calculado e propagado no sentido inverso para que os fatores das ligações sejam corrigidos. Este processo é repetido até o erro convergir para um valor predefinido [50], [51]. As redes com arquiteturas do tipo *Multilayer perceptron* são normalmente treinadas com métodos de *backpropagation*.

Quando os mínimos globais estão ocultos entre os mínimos locais, o método *backpropagation* pode entrar em alternância cíclica entre mínimos locais, sem grande melhoria de performance, tornando o treino da rede muito lento, o que é uma desvantagem. Outra das desvantagens deste método passa pela computação de gradientes, que requer diferenciabilidade dos dados, pelo que o método não consegue lidar com fatores descontínuos.

As principais vantagens das RNA são a sua capacidade em lidar com curvas de consumo energético não-lineares [52], bem como a sua tolerância a falhas e a dados incompletos. Uma vez treinadas, estas redes podem efetuar previsões rapidamente [49].

Paliwal & Kumar [53] indicam que as redes neuronais superam em muitos casos a performance dos modelos estatísticos, igualando-os no pior dos casos. Khosravi et al. [54] vão mais longe, indicando que os métodos que apresentam melhores resultados são os de Lógica Difusa e as RNA.

Yan et al. [55] apresentam um comparativo entre RNA e regressões lineares, concluindo que RNA têm uma precisão superior em previsões para curto-prazo. No entanto, em geral, não é possível comprovar a sua superioridade. Não há um método que supere os outros em todas as situações. Na Tabela 2.1 está uma pequena lista de métodos recomendados e suas aplicações [55].

Tabela 2.1 - Lista de métodos recomendados e suas aplicações (adaptado de Yan et al. [55]).

Aplicações		Métodos de modelação recomendados
Previsão da energia usada em todo o edifício	Curto prazo	RNA
	Longo prazo	Regressão e RNA
Análise da energia usada pelos componentes		Simulação detalhada
Estimativa das poupanças de energia	Modificações implementadas	Regressão e RNA
	Novas estratégias	Simulação detalhada

Existem mais métodos para além dos referidos, podendo também conjugar-se modelos estatísticos com modelos de inteligência artificial para se obter melhores resultados. Estes métodos são denominados híbridos. A principal vantagem destes métodos é que permitem considerar apenas um número de dados limitado e os parâmetros de entrada não precisam de ser definidos no início da simulação, apenas estar dentro de um intervalo [12], [56].

2.3 Ocupação de edifícios

Já foi referida anteriormente neste trabalho a importância da ocupação de um edifício no seu consumo energético. Seja pela utilização de equipamentos elétricos e eletrônicos, iluminação, ou sistemas de climatização em prol do bem-estar dos ocupantes, a ocupação tem sempre um forte impacto no consumo energético. Devido à enorme incerteza associada ao número real de presenças e às suas variações pontuais, não é possível fazer previsões da ocupação para determinados instantes com base em expectativas ao acaso, devendo ser monitorizada em tempo real [57].

2.3.1 Perfil de ocupação

Para determinar o perfil de ocupação de um edifício, é necessária a existência de formas de controlo da ocupação, para aquisição de dados relativos à movimentação de pessoas. Essas formas de controlo serão descritas posteriormente. Um perfil de ocupação representa-se pelo número de pessoas (ou um fator representativo desse número) em ordem ao tempo (seja por hora, dia, mês, etc.).

Na Figura 2.3 estão representados os perfis de ocupação para dias úteis e fim-de-semana do edifício de administração de uma universidade, obtidos de Davis III & Nutter [58]. É possível ver que as horas de expediente estão situadas entre as 7h e as 18h, pois os fatores de ocupação são mais elevados entre essas horas. De igual forma, na Figura 2.4 estão representados os perfis de ocupação da biblioteca da mesma universidade, obtidos da mesma fonte. Para esse caso, verifica-se que a ocupação média se prolonga até às 24h.

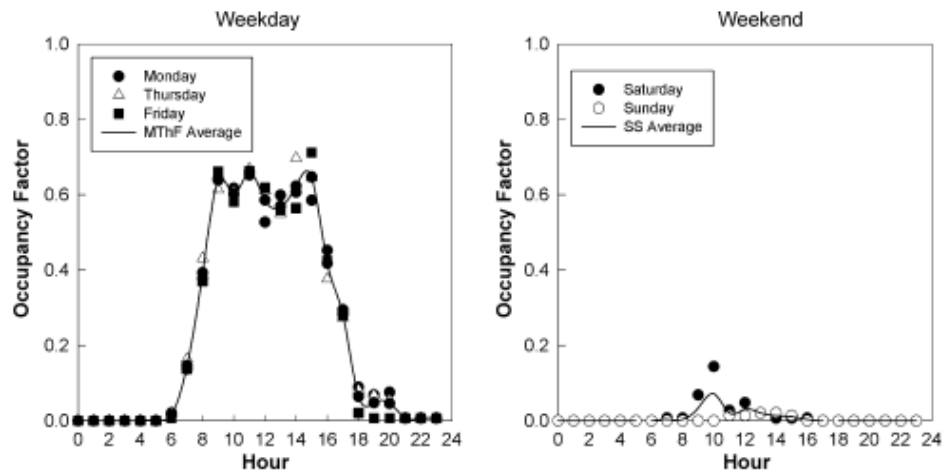


Figura 2.3 - Perfis de ocupação de dias úteis e fins-de-semana para o edifício de administração (retirado de Davis III & Nutter [58]).




Figura 2.4 - Perfis de ocupação de dia úteis e fins-de-semana para a biblioteca (retirado de Davis III & Nutter [58]).

2.3.2 Métodos para determinação da ocupação

A ocupação de um determinado edifício pode ser obtida direta ou indiretamente. Diretamente quando é feita uma contagem ou detecção das entradas e saídas e, indiretamente, se for obtida através de outros fatores que a possam representar. Martani et al. [11] determinaram a ocupação através do número de ligações à rede sem fios a cada momento, concluindo que este fator reflete claramente a ocupação, levando esta a uma variação do consumo energético superior a 60%. Liao & Barooah [57] referem diversas outras formas de determinar a ocupação: câmaras de vídeo com *software* capaz de detetar pessoas, *tripwires* óticos, sensores de movimento, sensores da concentração de CO₂, etc. No entanto, nenhum destes métodos permite obter valores exatos porque existe ruído dos sensores que leva a falhas na deteção.

As câmaras de vídeo poderão ter problemas a detetar pessoas quando haja pouca luminosidade e estão dependentes da qualidade do *software*. Sensores de movimento e *tripwires* óticos podem falhar em situações em que duas pessoas passam ao mesmo tempo ou podem sofrer influência de objetos que as pessoas transportem.

Os sensores de concentração de CO₂ apresentam um atraso de resposta e uma incerteza associada que não permite que sejam utilizados para determinar valores exatos da ocupação. Nesse sentido, de forma a obter resultados mais exatos, Ekwevugbe et al. [59] recorreram à redundância de sensores, utilizando vários tipos de sensores em paralelo, o que demonstrou ser eficaz e vantajoso. Os diversos tipos de sensores e a forma como foram interligados está representada na Figura 2.5.

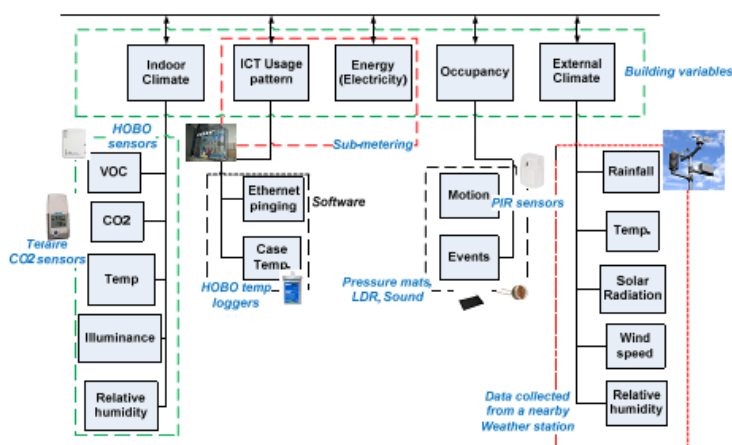


Figura 2.5 - Rede de sensores e sua interligação para previsão de consumo elétrico, considerada por Ekwevugbe et al. [59].

Hutchins et al. [60] abordam o problema da exatidão dos dados com 2 condições: a ocupação não pode ser negativa e a contagem deve ser sempre posta a zero no início de cada dia, para evitar erros propagados.

3 Solução proposta

Pretende-se, com base no conhecimento da lotação do parque, avaliar a possibilidade de utilizar estes dados para efetuar uma previsão do consumo elétrico do edifício.

Para avaliar a influência da lotação do parque de estacionamento associado ao edifício no seu consumo elétrico foram realizadas várias etapas, que são enumeradas de seguida:

1. Aquisição de dados relativos à ocupação do edifício em questão.
2. Aquisição de dados relativos à lotação do parque de estacionamento do recinto.
3. Determinação da relação entre a lotação do parque de estacionamento e a ocupação do edifício.
4. Aquisição de dados relativos ao consumo elétrico real do edifício em questão.
5. Determinação da relação entre a lotação do parque e o consumo elétrico do edifício.

3.1 Caracterização do parque de estacionamento e do edifício

Pretende-se estudar a influência da lotação do parque de estacionamento associado a um edifício no consumo elétrico do mesmo, edifício sito no *campus* da Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa, nomeadamente, o edifício do Departamento de Engenharia Electrotécnica.

O parque de estacionamento do *campus* referido inclui os parques interiores e os periféricos, apresentados na Figura 3.1, sendo que foram todos contabilizados quanto ao número de entradas e saídas e a diferença entre estas foi considerada como a lotação do parque.

As entradas e saídas foram registadas em todas as portarias da Figura 3.1, referidas por “Px”, com $x \in \{1 \dots 7\}$, através da passagem de um cartão magnético individual. A base de dados foi obtida do Gabinete de Segurança do *campus*, entidade a cargo do registo. A capacidade total do parque é desconhecida, pois não há limite de admissões e verifica-se muitas vezes o estacionamento em locais não delimitados, podendo assim exceder facilmente a capacidade projetada.

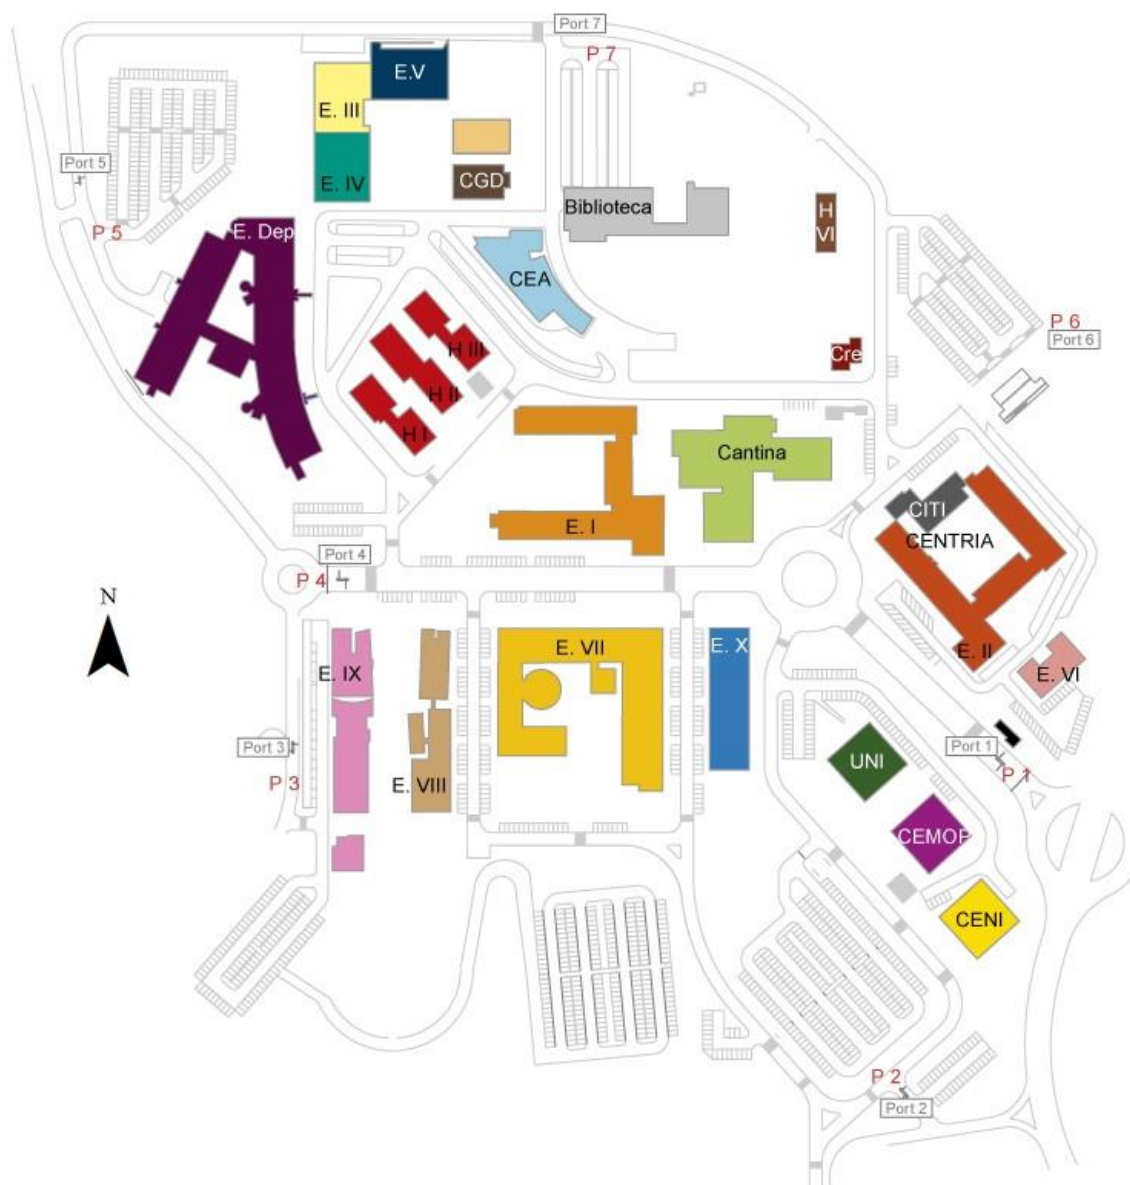


Figura 3.1 - Mapa do *campus* da Faculdade de Ciências e Tecnologia. As entradas são efetuadas pelas portarias P1 a P7 e contabilizadas [61].

O edifício a estudar, representado na Figura 3.1 por “E.X” é composto por 3 andares e uma cave, com 20 gabinetes de docentes e serviços, 18 salas de aula e 12 salas de investigação. As entradas e saídas são sempre efetuadas pela porta norte, característica do planeamento do edifício, o que torna a determinação do número de ocupantes a um dado instante menos complexa. O edifício possui um sistema AVAC centralizado, que distribui o ar climatizado pelas diversas salas. Dada a dimensão do edifício, é expectável um grande consumo elétrico por parte do sistema AVAC.

3.2 Aquisição de dados

3.2.1 Dados relativos à ocupação do edifício em questão.

Para a aquisição dos dados relativos à ocupação do edifício, desenvolveu-se um sistema constituído por um módulo que permitiu receber e processar os dados de sensores, guardando-os posteriormente, com a finalidade de desenvolver uma base de dados com o registo das presenças. Os sensores funcionam pelo conceito de *tripwire*, em que a deteção das passagens se faz aquando da alternância entre a existência ou não de obstáculos no caminho dos sensores. Foram utilizados sensores ultrassónicos (acústicos) ou sensores laser (óticos), como alternativa aos primeiros, dependendo de quais apresentarem melhores resultados. A informação a guardar na base de dados contém o número de ocupantes, a data e a hora.

3.2.2 Dados relativos à lotação do parque de estacionamento do recinto.

Neste trabalho, os dados relativos à lotação do parque de estacionamento do recinto foram obtidos a partir dos registos de controlo do sistema de acesso ao parque constituído por uma cancela e um detetor de *Radio-Frequency Identification* (RFID). Foram apenas considerados os dados relativos aos alunos, docentes e funcionários do Departamento de Engenharia Electrotécnica, pois são esses que constituem o grosso número dos utilizadores do edifício.

3.2.3 Dados relativos ao consumo elétrico real do edifício em questão.

De forma a obter-se uma medição dos consumos elétricos do edifício foi instalado um sistema de medição no Quadro Geral de Baixa Tensão (QGBT) do edifício. Este sistema monitoriza as 3 fases de alimentação elétrica do edifício ao nível do circuito geral e do circuito de AVAC. Desta forma, analisa e regista a potência ativa para cada fase, a intervalos regulares. Os dados são guardados num computador localizado na sala situada na cave do edifício. Para o efeito, foi desenvolvida uma aplicação em *Java* para obter os registos do sistema instalado e guardá-los num ficheiro de texto.

3.3 Processamento dos dados

3.3.1 Determinação da relação entre a lotação do parque de estacionamento e a ocupação do edifício.

Uma vez obtidos, os dados da lotação do parque e da ocupação do edifício foram processados, de forma a obter-se a relação entre os dois. Essa relação corresponde ao número de pessoas por carro. Como os dados da ocupação só estão disponíveis para um curto período de tempo (8 semanas), para se estender uma previsão a 9 meses foi necessário extrapolar os valores para as restantes semanas. Para isso, utilizou-se uma RNA de duas camadas, de tipo *feed-forward* com o treino a ser feito pelo método Levenberg-Marquardt *backpropagation*.

Como parâmetros de entrada da rede utilizaram-se o dia da semana, se é feriado ou não, e a hora do dia. O resultado da rede é uma previsão do número de pessoas por carro.

3.3.2 Determinação da relação entre a lotação do parque e o consumo elétrico do edifício.

Após obtidos todos os dados necessários, procedeu-se ao último ponto do trabalho, com vista a cumprir os objetivos. Para relacionar a lotação do parque com o consumo elétrico do edifício e, efetuar uma previsão desse consumo, foi utilizada outra RNA de tipo semelhante à utilizada no ponto 3.3. Como parâmetros de entrada da rede utilizar-se-á o dia da semana, se é feriado ou não, a hora do dia, o estado do sistema AVAC (ligado ou desligado) e o número de pessoas, obtido por extrapolação no ponto 3.3. O resultado da rede será a previsão do consumo elétrico do edifício.

4 Implementação

4.1 Módulo para determinar a ocupação do edifício

No intuito de determinar a ocupação do edifício e com base nos estudos efetuados *à priori*, desenvolveu-se um módulo que foi colocado à entrada do edifício, permitindo manter um controlo do número de eventos de entrada e saída, sendo que, a dado instante, a ocupação do edifício é obtida através da subtração do número de entradas pelo número de saídas. Optou-se pela implementação com recurso a uma placa microcontroladora Arduino Duemilanove com um controlador ATmega328 (Figura 4.1), pela sua facilidade de utilização e familiaridade da linguagem de programação em C, na qual se implementaram todas as operações aritméticas, bem como a análise de sensores e armazenamento dos dados.



Figura 4.1 - Arduino Duemilanove.

Para registar os eventos de entradas e saídas são necessários sensores para a deteção de passagens. Para o efeito, optou-se inicialmente por utilizar dois sensores ultrassónicos de medição de distâncias, modelo HC-SR04, colocados no teto, por cima da porta de entrada do edifício. A razão pela qual são usados dois sensores deve-se à necessidade de se saber a direção do movimento da pessoa, de forma a determinar se esta está a entrar ou a sair do edifício. A deteção de passagens será feita através da variação das distâncias medidas pelos sensores. O sensor que é ativado em primeiro lugar determina a direção do movimento.

Para a medição da distância é produzida uma onda sonora com uma frequência de 40KHz que é emitida por um altifalante que faz parte do sensor, sendo essa onda sonora refletida no objeto e captada por um microfone, fazendo também parte do sensor. O intervalo temporal entre a emissão e recepção do eco é medido e a distância d ao objeto é determinada por:

$$d = \frac{vt}{2}$$

Com a velocidade da propagação do som no ar a 15°C $v \approx 340$ m/s e sendo o tempo de reflexão t , cada centímetro é percorrido em 29,4 microssegundos. Este valor é a soma das distâncias percorridas pelo som enviado e o seu eco recebido, logo deve ser dividido por 2 para se obter a distância d ao objeto.

Quando a distância medida pelo sensor é inferior à distância ao chão, significa que há uma obstrução por baixo deste (como na passagem de uma pessoa). Para se saber a direção do movimento (entrada ou saída) são necessários dois sensores, detetando dessa forma qual é ativado primeiro. Na Figura 4.2 está representado o modo de funcionamento dos sensores ultrassônicos. Esta solução foi posteriormente substituída devido à sua incapacidade para cumprir corretamente o pretendido, como será esclarecido mais à frente.




Figura 4.2 - Modo de funcionamento dos sensores ultrassónicos, à passagem de uma pessoa.

A solução substituta da anterior, também desenvolvida neste trabalho, que se revelou apta ao registo dos eventos, foi a utilização de dois emissores laser e duas resistências fotossensíveis *Light Dependent Resistor* (LDR) que funcionam como recetores. Os lasers e as resistências foram colocados nas paredes interiores oeste e este, respetivamente. O microcontrolador foi colocado dentro de uma caixa, no teto, à entrada do edifício, como irá ser descrito posteriormente.

O sistema funciona através do conceito *tripwire*, detetando os eventos, através da interrupção do feixe do laser projetado na resistência, aquando da passagem da pessoa. Um esquema do processo de entrada está representado na Figura 4.3. Quando uma pessoa interrompe primeiro o feixe 1, significa que o seu movimento é no sentido de entrada. O processo de entrada continua com o feixe 2 a ser interrompido. Quando ambos os feixes ficam novamente desimpedidos, significa que a passagem da pessoa terminou e é incrementado o valor de ocupação total.




Figura 4.3 - Esquema de funcionamento dos lasers e resistências, à passagem de uma pessoa.

O processo de saída é idêntico ao de entrada, pela ordem inversa de interrupção dos feixes. No final é decrementada a ocupação total, com restrição ao número mínimo de zero ocupantes, isto é, caso a contagem anterior seja zero, não é decrementada. A máquina de estados representativa de como os processos de entrada/saída são efetuados está representada na Figura 4.4. E1 e E2 representam a existência de um obstáculo ao laser e só podem tomar os valores “1” e “0”, sendo que o primeiro indica existência e o segundo ausência. Um *timeout* representa um processo do ciclo da máquina de estados que não foi completado com sucesso. Significa isso que houve uma detecção de um obstáculo num dos sensores mas não foi detetado nenhum obstáculo no outro sensor, num período de 4 segundos. Este *timeout*, apesar de implementado, não foi utilizado mas poderia ser útil no sentido de se obter uma precisão superior na contagem, entrando como fator no cálculo do número de pessoas.

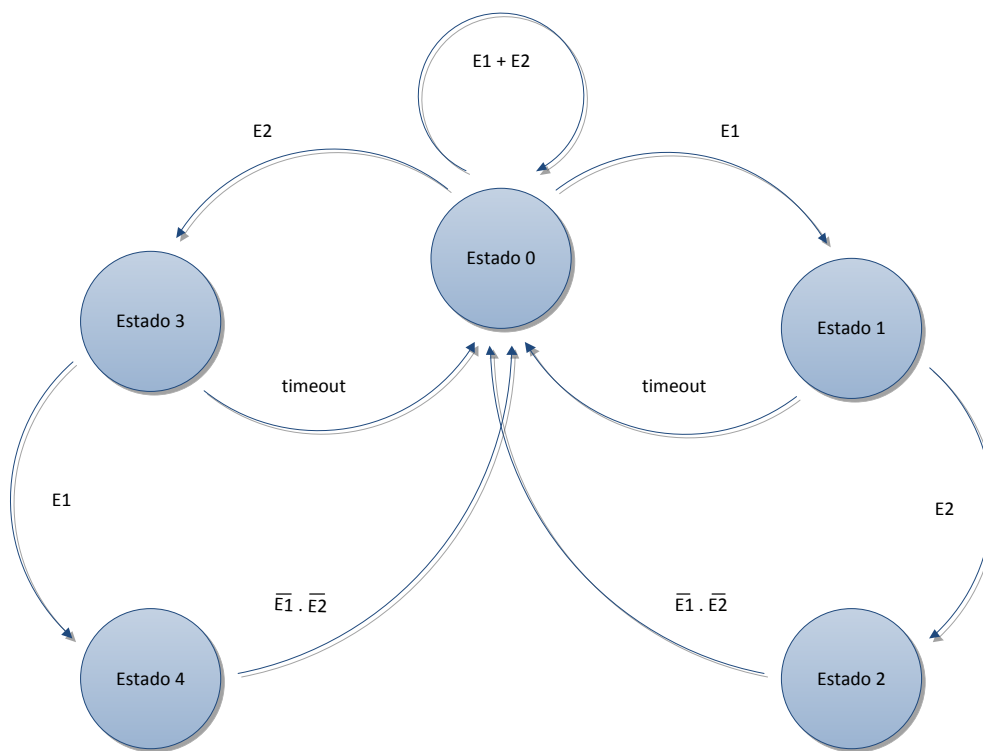


Figura 4.4 - Máquina de estados dos processos de entrada/saída.

Os dados foram guardados inicialmente num cartão microSD, em ficheiro de texto, com recurso a uma *Breakout Board* da marca Transflash para o Arduino. Posteriormente, foi desenvolvido um sistema que permitiu enviar o estado dos sensores para um computador situado numa sala adjacente, através de uma ligação série RS-232. Este computador corre uma aplicação desenvolvida em linguagem C++ que permite não só guardar os registos num ficheiro de texto, bem como monitorizar remotamente o funcionamento de todo o sistema (Figura 4.5). O ficheiro contém a data e hora; o número total de ocupantes do edifício para o instante da gravação no ficheiro; o número total de entradas acumuladas desde o último *reset*; o número total de saídas acumuladas desde o último *reset* e o número de *timeouts* ocorridos entre a última gravação e a atual. O ficheiro é gravado com uma periodicidade de 1 minuto e os dados são sucessivamente acrescentados ao mesmo. Para diminuir a influência dos erros propagados, as contagens são reiniciadas todos os dias às 5 horas.

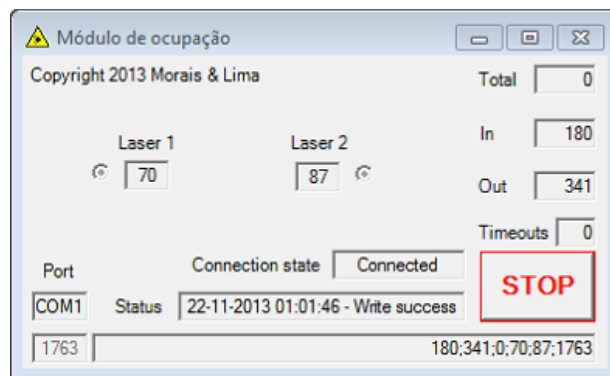


Figura 4.5 – Interface da aplicação desenvolvida para gravação dos dados e monitorização do sistema.

Para a construção do módulo, foi projetado um circuito elétrico com as características indicadas na Figura 4.6, onde L1 e L2 representam os lasers e R1 e R2 representam as resistências LDR.

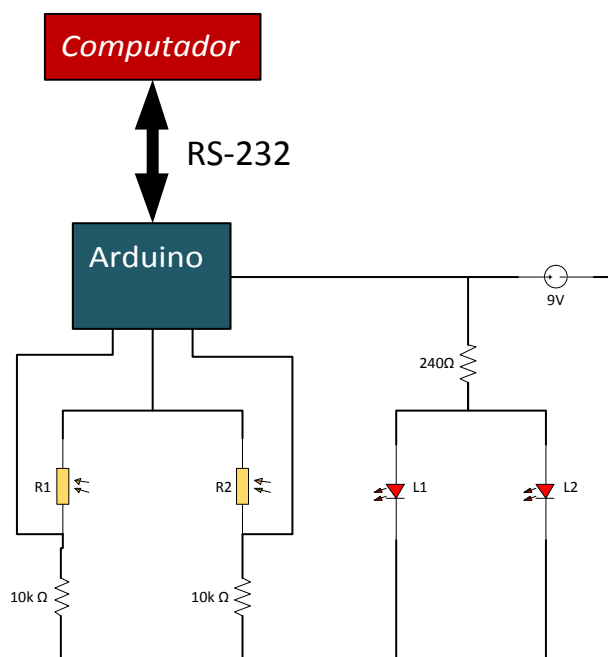


Figura 4.6 - Esquema de ligações elétricas do módulo de ocupação utilizado.

Foi usada uma caixa de derivação de dimensões 20x16x8 cm, na qual foi colocado o Arduino e uma *breadboard* para ligação dos fios condutores (Figura 4.7).

Foram utilizados emissores laser da marca Wenta Electronic, modelo LM-102-B119, colocados dentro de uma caixa de dimensões 22x9x9 cm. Para limitar a corrente máxima nos lasers, como medida de prevenção ao sobreaquecimento, foi colocada uma resistência de 240Ω , em série com os lasers. Assim, os lasers são alimentados pela mesma fonte de 9V que alimenta o Arduino, com uma tensão de 2,25V, inferior à nominal de 3,1V. Na Figura 4.8 apresenta-se a caixa que contém os lasers, após a sua instalação no edifício.

No circuito das resistências LDR, são usadas duas resistências adicionais de $10k\Omega$, de modo a ser aplicado um divisor de tensão, cujo valor da tensão aos terminais destas resistências é proporcional à luminosidade incidente nas LDR. Essa tensão é medida numa entrada analógica do Arduino, permitindo saber quando o feixe do laser é interrompido. As resistências LDR foram colocadas na parede oposta à dos emissores laser, dentro de uma caixa idêntica à dos últimos (Figura 4.9).



Figura 4.7 - Caixa onde foi colocado o Arduino, após a sua instalação no edifício.



Figura 4.8 - Caixa que contém os emissores laser, após instalação no edifício.



Figura 4.9 - Caixa que contém as resistências LDR (em baixo) e a caixa com o Arduino (em cima).

Na Figura 4.10 pode ver-se o aspeto final do módulo para determinar a ocupação, após concluída a sua instalação. Em cima, a caixa com o Arduino. À esquerda, a caixa com os emissores laser. À direita, a caixa com as resistências LDR.




Figura 4.10 - Módulo para determinar a ocupação, após a sua instalação.

4.2 Medidor de consumo elétrico

Com a finalidade de determinar o consumo elétrico do edifício, foi implementada uma solução com a arquitetura da Figura 4.11, da autoria de José Lima, coorientador deste trabalho. Nesse sentido, segundo comunicação pessoal do autor, foram instalados 2 analisadores de energia multifunções Algodue UPT210 no QGBT do edifício, o primeiro a seguir ao disjuntor geral e o segundo a seguir ao disjuntor de alimentação do sistema AVAC, de forma a obter-se a potência ativa instantânea de todo o edifício e do sistema AVAC, em separado. Estes analisadores de energia utilizam um protocolo de comunicação série Modbus por RS-485 para transmitir os dados. Estes dados são armazenados num *Data Logger* Lumel PD22 e enviados para um servidor instalado na sala da cave do edifício através da rede Modbus. Um módulo Lumel PD8 Gateway Ethernet/ RS-485 faz a conversão do protocolo RS-485 em Ethernet para comunicação com o servidor. No servidor, corre uma aplicação em *Java*, desenvolvida pelo mesmo autor, que recebe os dados relativos ao consumo elétrico, guardando-os num ficheiro de texto. A aquisição dos dados foi feita ao longo de 9 meses, com intervalos de 1 minuto entre amostras, correspondendo ao período entre o início de Outubro e finais de Junho.

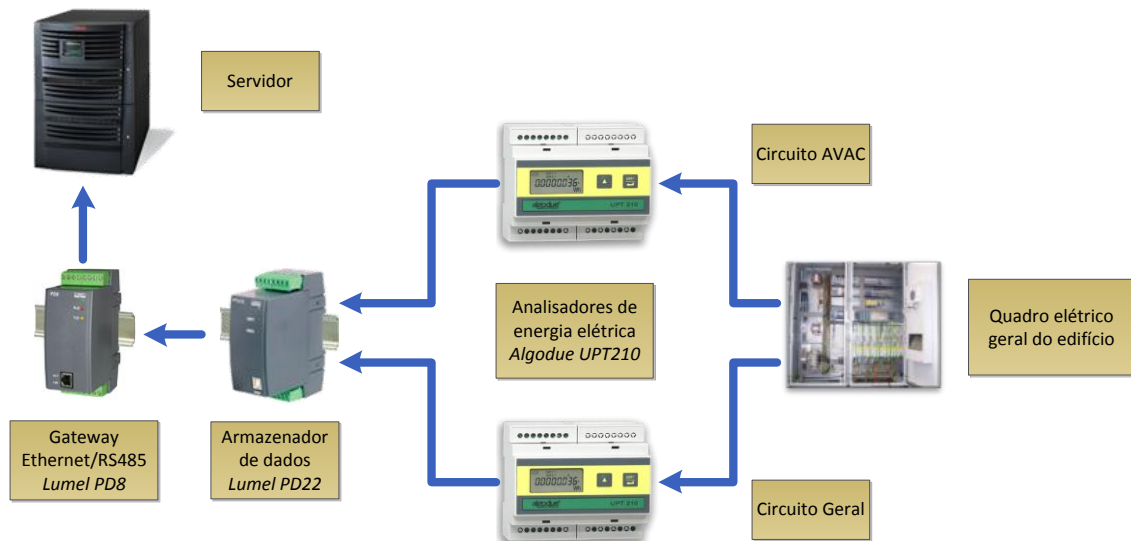


Figura 4.11 - Esquema da arquitetura do sistema de análise de consumo elétrico do edifício e do sistema AVAC.

4.3 Processamento de dados e extrapolações

Os dados da ocupação do edifício, da lotação do parque de estacionamento e do consumo elétrico do edifício foram processados individualmente no sentido de serem utilizados em RNA, os dois primeiros numa e o último noutra. Para as previsões que se pretendiam efetuar, foi criada uma rede de dados com a configuração da Figura 4.12. Os dados obtidos da lotação do parque, ocupação do edifício e consumo do mesmo, estão representados a verde na figura, com as indicações “real” e “9 meses”. Os resultados de previsões e extrapolações estão representados a vermelho. Os dados a azul, são os restantes *inputs* das RNA utilizados. Os dados representados como entradas, por baixo das duas RNA, correspondem aos valores históricos dos dados que se pretendiam obter como previsões ou extrapolações. O bloco “DIVISOR” realiza a divisão entre a ocupação do edifício e a lotação do parque, sendo que o bloco “X” realiza o produto entre a previsão do número de pessoas por carro e a lotação do parque.

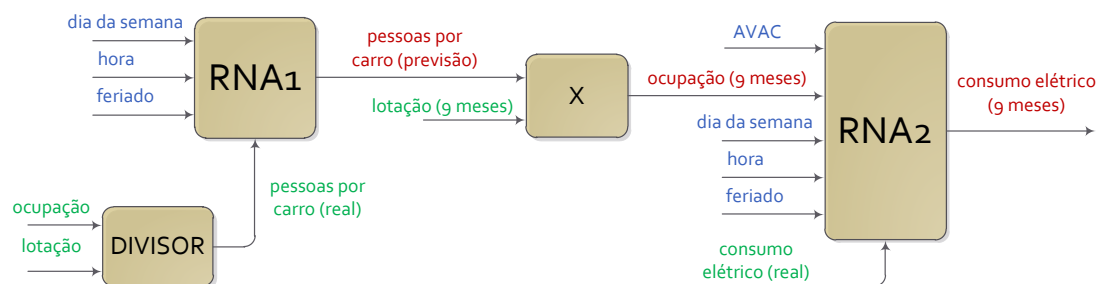


Figura 4.12 - Visão geral de toda a rede de dados utilizada no trabalho.

Tendo em consideração a capacidade de proporcionar resultados fiáveis e uma interface intuitiva que torna rápida e eficaz a utilização de RNA, optou-se pela utilização da ferramenta *Neural Network Toolbox™* do ambiente de simulação Matlab (Figura 4.13), para efetuar todas as simulações [62].

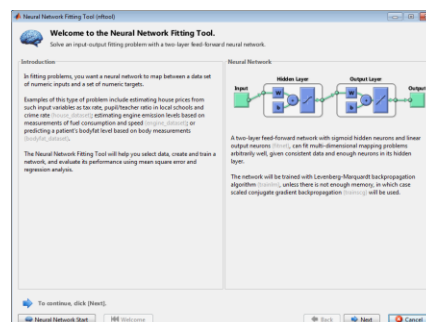


Figura 4.13 - Ferramenta Neural Network Toolbox™ do ambiente de simulação Matlab.

5 Resultados e discussão

5.1 Ocupação do edifício

Após a implementação do sistema e a sua instalação no edifício, procedeu-se ao teste do mesmo. O primeiro teste foi realizado com os sensores ultrassónicos e, na prática, constatou-se a sua incapacidade em detetar eventos de entrada e saída, como referido anteriormente. Esse facto é inerente ao funcionamento dos sensores ultrassónicos e é causado pela reflexão, refração e dispersão do som nas roupas ou na pele [63]. Os registos apresentaram sempre uma ocupação de zero pessoas, bem como zero entradas e zero saídas, revelando-se impossível detetar pessoas, devido à distância a que os sensores foram colocados. Para a solução ser viável, seria necessário que os sensores fossem colocados a uma distância inferior a 50 centímetros do obstáculo a detetar, valor esse determinado experimentalmente, o que não foi possível concretizar devido às características do local de instalação, bem como às diferentes estaturas das pessoas.

Procedeu-se de seguida à implementação e teste da solução com sensores óticos. Após um curto período de testes, verificou-se que os resultados obtidos refletiam o comportamento da ocupação do edifício. Prolongou-se então o tempo de aquisição de dados para as 8 semanas, com um minuto de intervalo entre amostras. Os resultados obtidos são apresentados na Figura 5.1 e demonstram um perfil de ocupação semelhante ao esperado, com as quintas-feiras a serem os dias com registo de maior ocupação e os fins-de-semana a apresentarem o menor nível de ocupação.




Figura 5.1 - Perfil de ocupação do edifício para 8 semanas. Os “Q” a vermelho representam as quintas-feiras.

Como pode ver-se pela Figura 5.1, as segundas e terças-feiras apresentam níveis de ocupação tipicamente semelhantes.

Por norma, as quartas-feiras são o dia útil com menor ocupação, o que reflete a realidade devido, acima de tudo, ao facto de não haver aulas da parte da tarde, não só no edifício, mas em todo o *campus*.

Observou-se que as quintas-feiras são o dia com uma ocupação maior em relação aos restantes, presumivelmente, motivado pelos horários das aulas. Pode ver-se na Figura 5.1 que uma das quintas-feiras (dia 27 da amostragem) apresenta um nível de ocupação máximo muito inferior ao que é típico, por coincidir com o feriado do dia 25 de Abril. Esse feriado será tido em conta quando for feita a previsão do consumo elétrico.

Observou-se também que as sextas-feiras, tipicamente, apresentam uma ocupação semelhante à de segunda e terça-feira. No entanto, numa das sextas-feiras (dia 7 da Figura 5.1) existia ainda um registo de 138 pessoas no edifício, à hora de *reset*, valor este muito superior ao número de presenças numa sexta-feira típica. Esta imprecisão dos resultados deve-se ao facto de nesse dia ter-se realizado o evento “ExpoFCT” no *campus* da universidade, o que levou à existência de um fluxo de grupos de visitantes a entrar e sair simultaneamente do edifício e ao facto dos sensores não terem capacidade para diferenciar a passagem de mais do que uma pessoa em simultâneo, por ser interpretado como um único obstáculo.

Nos fins-de-semana, a ocupação é muito inferior aos restantes dias, traduzindo a realidade de, por norma, não haver atividades no departamento, seja ao sábado ou ao domingo.

Entre dois dias da semana, por vezes estão representadas pequenas flutuações nos valores de ocupação e ocupação residual. Ambos resultam da imprecisão dos sensores, que se traduz em ruído na contagem. Como forma de redução desse ruído poderiam ser utilizados os registos de *timeouts* referidos anteriormente. No entanto, não foram utilizados, pois não se enquadram no âmbito deste trabalho.

Com os dados de ocupação foi gerado um perfil semanal com a ocupação média por dia. O perfil está representado na Figura 5.2. Note-se que na figura estão assinaladas as 12h de cada dia com um segmento vermelho no eixo das abcissas. Pode comparar-se em mais detalhe os níveis de ocupação a cada dia da semana e é possível distinguir melhor os dois picos de máximos de ocupação a cada dia, com a hora de almoço a corresponder às amostras entre dois picos. Comparando com a Figura 2.3, verifica-se que os dias têm um perfil com um formato semelhante com declive positivo nas primeiras horas do dia, com depois um declive negativo à hora de almoço, voltando a aumentar a ocupação da parte da tarde, diminuindo ao fim do dia e mantendo-se residual pela noite dentro.




Figura 5.2 - Perfil de ocupação semanal médio do edifício. No eixo das abcissas estão assinaladas a vermelho as 12h de cada dia.

5.2 Lotação do parque de estacionamento

Os dados referentes à lotação do parque de estacionamento estão representados na Figura 5.3 e foram, como referido, fornecidos pelo Gabinete de Segurança do *campus*. Estes dados contêm os eventos de entrada e saída em todos os parques do recinto, por parte dos alunos, docentes e funcionários do Departamento de Engenharia Electrotécnica. Por isso, foi necessário processar os eventos para determinar a lotação correspondente aos docentes, alunos e funcionários do Departamento de Engenharia Electrotécnica para cada instante. Os dados dizem respeito a 9 meses, sendo que foram truncados em Excel para corresponderem às mesmas 8 semanas dos dados de ocupação do edifício. Como os dados são registados por eventos, não são periódicos, existindo assim dias com poucos registos. É de referir que há dias que não estão representados nessa figura, pois o eixo temporal está comprimido devido ao número reduzido de eventos ao fim de semana e feriados. Assim, não é possível distinguir esse tipo de dias no gráfico devido ao reduzido número de amostras. A função de pessoas por carro foi obtida para cada amostra do número de pessoas e do número de carros através da divisão entre eles.




Figura 5.3 - Lotação do parque (a laranja) vs ocupação do edifício (a azul) vs pessoas por carro (a roxo).

Na Figura 5.3 pode ver-se a variação da lotação do parque ao longo dos dias, representada a laranja, a ocupação do edifício, representada a azul, ambas com o eixo das ordenadas do lado esquerdo e o número de pessoas por carro a roxo, com o eixo das ordenadas do lado direito. Verifica-se que, apesar de não coincidirem em número, as curvas de ocupação e de lotação apresentam comportamentos semelhantes em termos de declives ao longo de cada dia. Existem diversas razões pela qual as curvas anteriores não coincidem em número, nomeadamente o facto de muitos alunos do departamento terem aulas noutros edifícios, especialmente no caso das disciplinas de tronco comum, como sejam as Análises Matemáticas ou Física e por isso, embora contabilizados no parque, não o foram no edifício.

De notar que existem vários picos irrealistas na curva de pessoas por carro (Figura 5.3), que ocorrem normalmente por volta das 8h - sendo o mais evidente no dia 6 da mesma figura, com um pico de 64 pessoas por carro - causados pelo facto de ter sido a esta hora que chegou o primeiro carro ao parque, existindo já pessoas contabilizadas no edifício a esse instante, que se terão deslocado por outro meio, ou que não fazem parte do departamento, como sejam alunos de outros departamentos com aulas de disciplinas a ter lugar nesse departamento.

5.3 Extrapolação dos valores de ocupação para 9 meses

Com os dados de ocupação do edifício para 8 semanas e os dados do parque truncados para as mesmas 8 semanas, ambos referidos no ponto anterior, desenvolveu-se uma RNA com a finalidade de obter uma curva de previsão do número de pessoas por carro para essas 8 semanas, de forma a criar um perfil geral que possa ser aplicado na previsão do consumo elétrico para outras semanas.

Dos valores de pessoas por carro obtidos em 5.2, foi decidido eliminar-se todas as amostras de pessoas por carro com valores acima de 3, pelo facto de serem valores irrealistas, tendo em conta a realidade constatada, e reduzirem a precisão da previsão a efetuar. Foram também eliminadas as respetivas amostras da ocupação do edifício e a lotação do parque correspondentes. Num universo de cerca de 32 mil amostras, foram eliminadas 258 amostras, o que representa aproximadamente 1% destas, um valor negligenciável, tendo em conta o aumento de precisão da previsão realizada, como constatado nas simulações preliminares.

A RNA foi construída com a configuração da Figura 5.4. Os *inputs* utilizados foram: a hora, o dia da semana, se é ou não feriado e o número de pessoas por carro (real, obtido pela divisão entre a ocupação e a lotação (representado a verde na Figura 5.4). O resultado foi o número de pessoas por carro (previsão). A parametrização da rede foi feita com 10 *layers* ocultas. A simulação consiste de treino, validação e teste. O treino da rede foi feito pelo método Levenberg-Marquardt *backpropagation* com 70% das amostras, escolhidas aleatoriamente para treino, sendo que as restantes foram utilizadas 15% para validação e 15% para teste. Foram efetuadas 5 simulações, sendo que no final foi feita uma média dos valores das 5. Com esta configuração, obtiveram-se os resultados da Figura 5.5, na qual estão representados os valores do número de pessoas por carro da previsão (a azul) e os valores reais (a laranja). Pode ver-se que a previsão não acompanha os picos maiores dos valores reais, pois é baseada em modelos de inteligência artificial que utilizam funções matemáticas na parametrização, não permitindo oscilações de valores muito repentinas.

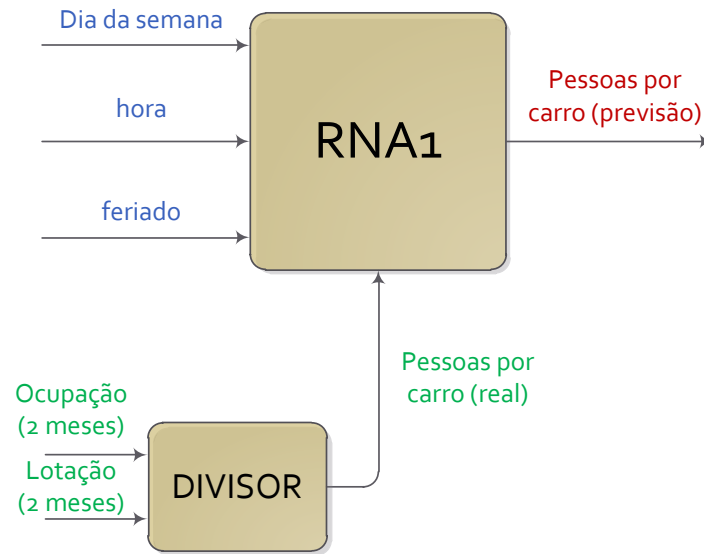


Figura 5.4- Configuração da RNA utilizada para criar um perfil geral de pessoas por carro.




Figura 5.5 - Resultado da simulação em Matlab com RNA do perfil de pessoas por carro. A previsão está representada a azul e os valores registados a laranja.

A performance da rede está representada na Tabela 5.1. Pode ver-se que o *Mean Squared Error* (MSE) aproxima-se de 0,09. O valor obtido neste trabalho, para este ponto, como se aproxima de 0, é um bom resultado. A correlação é aproximadamente de 0,78. É também um bom resultado, na medida em que “um” indica uma previsão perfeita e “zero” uma previsão irrealista.

Tabela 5.1 - Resultados de MSE e correlações das 5 simulações realizadas, com dados de 8 semanas.

Número da simulação	Treino		Validação		Teste	
	MSE	Correlação	MSE	Correlação	MSE	Correlação
1	8,78E-02	7,91E-01	9,69E-02	7,70E-01	9,38E-02	7,69E-01
2	8,75E-02	7,89E-01	9,28E-02	7,81E-01	9,15E-02	7,87E-01
3	8,98E-02	7,86E-01	8,33E-02	7,94E-01	9,61E-02	7,71E-01
4	8,81E-02	7,89E-01	8,43E-02	8,01E-01	8,79E-02	7,91E-01
5	9,21E-02	7,79E-01	9,26E-02	7,70E-01	9,13E-02	7,87E-01
Média	8,91E-02	7,87E-01	9,00E-02	7,83E-01	9,21E-02	7,81E-01

Os resultados aqui representados dizem respeito a 8 semanas. Para se fazer a previsão do número de pessoas no edifício para 9 meses, foi necessário decompor a previsão obtida de 8 semanas em dias da semana. Para isso, os resultados foram processados em Excel, criando-se um perfil geral semanal, através da média de pessoas por carro a cada dia da semana. Essa média foi multiplicada pelos dados de 9 meses sobre a lotação do parque, obtendo-se assim a previsão de ocupação do edifício nesses 9 meses.

Para demonstrar a validade dessa previsão, desenvolveu-se uma RNA idêntica à referida anteriormente neste ponto, com a diferença de que foram utilizados os dados de apenas 6 semanas. Pretende com isso demonstrar-se se a ocupação prevista para as semanas que não foram consideradas na RNA é semelhante à real. Os resultados estão representados na Figura 5.6 onde as duas primeiras semanas não foram incluídas na previsão. Novamente se verifica que a previsão não acompanha os valores reais nas situações em que há variações muito repentinas do valor real. Em particular, para o 7º dia representado na Figura 5.6, no qual, como já referido, teve lugar o evento “ExpoFCT”, pelo que a previsão está demasiado longe da curva de ocupação real para esse dia. No entanto, para os restantes dias das duas primeiras semanas, verifica-se que a previsão se aproxima dos valores reais, pelo que é um bom indicador de que o método utilizado é adequado e válido, mostrando baixo MSE e boa correlação, conforme Tabela 5.2 onde estão representados os valores de MSE e correlação das 5 simulações com dados de 6 semanas. Pode constatar-se que tanto o MSE como a correlação melhoraram em relação às simulações com todas as semanas incluídas, pelo facto de terem sido usados menos dias com ocupação fora dos valores usuais.




Figura 5.6 - Perfil de ocupação real (a cinzento) vs previsto (a amarelo).

Tabela 5.2 - Resultados de MSE e correlações das 5 simulações realizadas, com dados de 6 semanas.

Número da simulação	Treino		Validação		Teste	
	MSE	Correlação	MSE	Correlação	MSE	Correlação
1	5,70E-02	8,56E-01	5,64E-02	8,61E-01	6,44E-02	8,43E-01
2	5,63E-02	8,60E-01	6,14E-02	8,41E-01	5,96E-02	8,48E-01
3	6,15E-02	8,46E-01	6,10E-02	8,43E-01	6,35E-02	8,38E-01
4	5,55E-02	8,58E-01	6,38E-02	8,55E-01	5,13E-02	8,70E-01
5	6,09E-02	8,48E-01	6,05E-02	8,45E-01	6,52E-02	8,30E-01
Média	5,82E-02	8,53E-01	6,06E-02	8,49E-01	6,08E-02	8,46E-01

5.4 Previsão do consumo elétrico do edifício

Uma vez obtidos os resultados referidos no ponto anterior e obtida daí a previsão para 9 meses de ocupação do edifício, foi desenvolvida outra RNA, que permitiu obter a previsão do consumo elétrico do edifício, para 9 meses. A Figura 5.7 apresenta a configuração que foi usada para a parametrização da nova RNA. Os parâmetros utilizados foram descritos no ponto 4.3. O resultado do produto entre a média semanal da previsão do número de pessoas por carro e a lotação do parque para 9 meses corresponde à ocupação prevista para o edifício num período de 9 meses. De notar que se constatou que o sistema AVAC nunca foi ativado entre 3 de Dezembro e 4 de Junho e no restante período o seu ciclo de funcionamento correspondia a estar ativo por períodos de tempo variáveis entre 30 a 48 minutos, comutando depois para o estado de desativado, no qual permanecia durante aproximadamente uma hora.

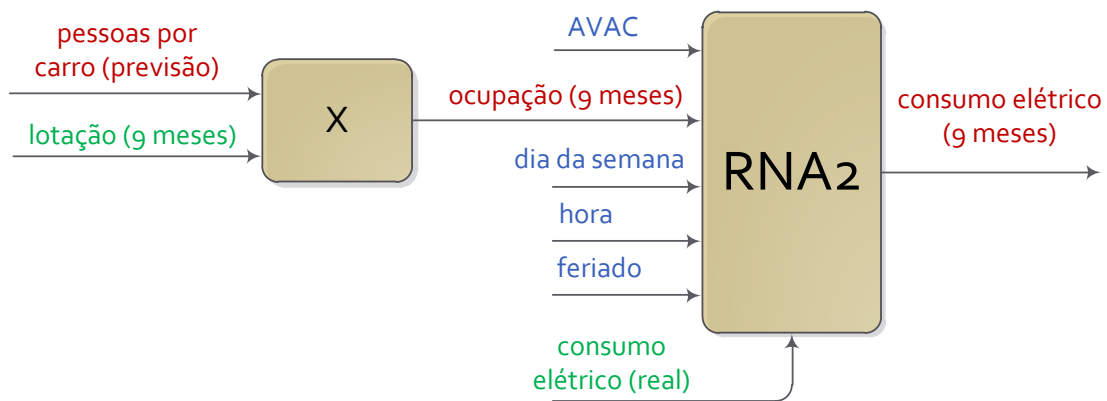


Figura 5.7 - Configuração da RNA utilizada para efetuar a previsão do consumo elétrico do edifício para 9 meses.

5.4.1 Previsão com o conjunto de dados completo

Das 5 simulações que foram efetuadas para esta RNA, foi feita a média das mesmas e obteve-se a previsão do consumo elétrico do edifício, para 9 meses. Os resultados estão representados na Figura 5.8, com o consumo real apresentado a roxo e o consumo previsto com os dados referentes ao AVAC e à ocupação do edifício incluídos, representados a laranja. Estes consumos estão normalizados entre 0 e 1, com 1 a representar o consumo máximo e 0 o mínimo. Da Figura 5.8 pode ver-se que os 2 conjuntos de dados são praticamente coincidentes, de tal forma que é difícil diferenciá-los. Não é facilmente visível a linha laranja, indicando que a previsão tem muita precisão.




Figura 5.8 - Resultado da RNA da previsão do consumo elétrico do edifício, com o consumo real (roxo) vs consumo previsto com os dados do AVAC e da ocupação (laranja).

Na Tabela 5.3 confirma-se que a previsão é bastante precisa, na medida em que todos os valores médios obtidos da correlação são iguais a 1 e os valores médios de MSE são muito pequenos (na casa dos milhares de milhão inferiores à unidade). É de referir que o intervalo entre as amostras 1150 e 4515 corresponde ao período de tempo referido anteriormente, no qual o sistema AVAC nunca foi ativado.

Tabela 5.3 - Resultados de MSE e correlações das 5 simulações realizadas da RNA para 9 meses, com dados do AVAC incluídos.

Número da simulação	Treino		Validação		Teste	
	MSE	Correlação	MSE	Correlação	MSE	Correlação
1	5,48E-10	1	5,14E-10	1	3,01E-08	1
2	1,21E-11		9,99E-12		1,15E-11	
3	9,01E-12		1,50E-11		1,86E-11	
4	2,14E-12		1,67E-12		2,30E-12	
5	4,54E-15		2,70E-13		4,12E-15	
Média	1,14E-10		1,08E-10		6,03E-09	

5.4.2 Previsão sem os dados do sistema AVAC

Foram feitas mais simulações com diferentes *inputs* da RNA₂, para determinar a influência de cada um. Como confirmado no ponto 5.4.1 e, tendo em conta que o consumo elétrico previsto com os dados do AVAC incluídos é praticamente coincidente com o consumo elétrico real, irá utilizar-se o primeiro como base de comparação nas simulações seguintes, como substituto do consumo elétrico real.




Figura 5.9 - Resultado da RNA da previsão do consumo elétrico do edifício, com o consumo previsto sem os dados do AVAC (roxo) vs consumo previsto com os dados do AVAC (verde).

Efetuararam-se 5 simulações com todos os *inputs* anteriormente referidos, com exceção dos dados relativos ao sistema AVAC. Na Figura 5.9 pode ver-se que a média das simulações efetuadas sem os dados do AVAC, a roxo, diferem acentuadamente nas amostras anteriores a 1150 e posteriores a 4515, quando comparadas com as simulações que incluíram os dados do AVAC, a verde na mesma figura. Verifica-se assim uma influência elevada do sistema de AVAC no consumo elétrico do edifício. De notar que cerca da amostra número 2700 existe uma discrepância entre as simulações que não se devia verificar, pois o AVAC nunca trabalhou nesse período de tempo. Pensa-se que será devida aos conjuntos de dados aleatórios escolhidos pelo Matlab para treino, validação e teste da RNA.

Na Tabela 5.4 estão representados os resultados de MSE e correlação obtidos destas simulações sem utilizar os dados sobre o funcionamento do AVAC, onde pode verificar-se que os resultados pioraram em relação à simulação com os dados completos. O MSE aumentou cerca de 80 milhões de vezes e a correlação diminuiu cerca de 30%. Assim, pode concluir-se

que o funcionamento do sistema AVAC tem uma grande importância no consumo elétrico do edifício.

Tabela 5.4 - Resultados de MSE e correlações das 5 simulações realizadas da RNA para 9 meses, sem dados do AVAC.

Número da simulação	Treino		Validação		Teste	
	MSE	Correlação	MSE	Correlação	MSE	Correlação
1	8,08E-03	7,16E-01	7,75E-03	6,94E-01	9,59E-03	6,64E-01
2	8,03E-03	7,09E-01	9,04E-03	6,76E-01	8,97E-03	6,92E-01
3	8,51E-03	6,96E-01	7,37E-03	7,36E-01	8,32E-03	6,95E-01
4	8,23E-03	7,03E-01	7,65E-03	7,30E-01	9,33E-03	6,72E-01
5	8,15E-03	7,05E-01	9,36E-03	6,70E-01	9,92E-03	6,36E-01
Média	8,20E-03	7,06E-01	8,23E-03	7,01E-01	9,23E-03	6,72E-01

5.4.3 Previsão sem os dados da ocupação do edifício

Como referido, foram feitas algumas simulações adicionais para determinar a influência de outros fatores. Neste ponto, foi avaliada a influência que os dados sobre a ocupação do edifício têm no consumo elétrico do mesmo. Para tal, efetuaram-se 5 simulações novamente, desta vez sem o *input* da RNA₂ relativo ao número de pessoas. A média dos resultados obtidos está representada a laranja na Figura 5.10, em comparação com a média dos resultados das simulações que incluem os dados do sistema AVAC (a verde).




Figura 5.10 - Resultado da RNA da previsão do consumo elétrico do edifício, com o consumo previsto com os dados do AVAC (verde) vs o consumo previsto sem os dados da ocupação do edifício (laranja).

Durante a preparação dos dados para as simulações verificou-se que a ativação ou não do sistema AVAC instalado no edifício não dependia da temperatura exterior ou interior nem da ocupação do edifício, funcionando periodicamente, como já referido, correspondendo a sua ativação ao funcionamento em plena carga e desativação a consumo nulo. Caso dependesse desses fatores, verificar-se-iam períodos de funcionamento aleatórios e/ou consumos elétricos com diferenças acentuadas.

Como pode ver-se pela Figura 5.10, sem os dados sobre a ocupação do edifício há uma redução na precisão da previsão do consumo elétrico, mais evidente nas amostras anteriores à 1150, nas quais o sistema AVAC funcionou periodicamente. Verifica-se, dessa forma, que há uma relação entre a ocupação do edifício e o consumo elétrico do edifício.

Pela Tabela 5.5 é possível ver que a correlação é de cerca de 0,8 e o MSE médio entre 5×10^{-3} e 6×10^{-3} , o que significa que houve uma diminuição da precisão na previsão do consumo elétrico sem os dados referentes à ocupação, relativamente à previsão efetuada do consumo elétrico com os dados completos. Esta situação deve-se ao facto dos dados relativos ao sistema AVAC terem sido usados nesta simulação, demonstrando estes uma importância maior quando se pretende fazer uma previsão de consumo elétrico.

Tabela 5.5 - Resultados de MSE e correlações das 5 simulações realizadas da RNA para 9 meses, sem dados da ocupação do edifício.

Número da simulação	Treino		Validação		Teste	
	MSE	Correlação	MSE	Correlação	MSE	Correlação
1	5,10E-03	8,23E-01	5,39E-03	8,20E-01	6,92E-03	7,98E-01
2	5,15E-03	8,24E-01	6,07E-03	8,17E-01	5,87E-03	7,99E-01
3	5,43E-03	8,23E-01	5,87E-03	7,96E-01	6,22E-03	7,67E-01
4	5,28E-03	8,22E-01	5,79E-03	8,04E-01	5,76E-03	8,11E-01
5	5,49E-03	8,19E-01	4,88E-03	8,18E-01	5,83E-03	8,07E-01
Média	5,29E-03	8,22E-01	5,60E-03	8,11E-01	6,12E-03	7,96E-01

5.4.4 Comparação entre as previsões sem os dados do sistema AVAC e sem os dados da ocupação do edifício

Após realizadas todas as simulações pretendidas no âmbito deste trabalho, é de referir a importância tanto dos dados relativos à ocupação do edifício, como os dados relativos ao funcionamento do sistema AVAC. Na Figura 5.11 é possível comparar as 2 previsões, pelos resultados obtidos das simulações sem os dados do sistema AVAC, a roxo, e sem os dados relativos à ocupação do edifício, a laranja. Pode observar-se a discrepância entre os 2 perfis, em 2 intervalos diferentes: No intervalo anterior à amostra 1150 e posterior à 4515, que é o período para o qual houve funcionamento do sistema AVAC, a curva a laranja aproxima-se mais do perfil real, na medida em que conta com os dados do AVAC; No intervalo entre a amostra 1150 e 4515 a curva a roxo aproxima-se mais do perfil real, porque incluiu os dados da ocupação na previsão e os dados do sistema AVAC não tiveram qualquer influência nesse período.

No entanto, observa-se que a previsão efetuada sem os dados de ocupação foi melhor que a previsão sem os dados do sistema AVAC, o que indica uma influência da ocupação inferior à do sistema AVAC no consumo elétrico, para o caso estudado neste trabalho.




Figura 5.11 - Resultado da RNA da previsão do consumo elétrico do edifício, com o consumo sem os dados do AVAC (roxo) vs consumo previsto sem os dados da ocupação (laranja).

6 Conclusões e trabalho futuro

No presente trabalho pretendia avaliar-se a correlação entre a lotação do parque de estacionamento do *campus* de uma instituição com a ocupação de um determinado edifício sito no mesmo *campus*, bem como verificar a possibilidade de utilizar esta ocupação como um fator que permitisse efetuar uma previsão de consumo elétrico do mesmo edifício. De igual forma, pretendia estudar-se a influência da ocupação no consumo elétrico do edifício e compará-la com a influência do sistema AVAC.

Nesse sentido, desenvolveu-se um módulo de utilização temporária de forma a determinar a ocupação do edifício durante 8 semanas. Dos sistemas testados, ultrassónico e ótico, apenas o segundo, constituído por emissores laser e recetores LDR, controlados por um sistema Arduino, se mostrou suficientemente eficaz para se manter funcional durante toda a experiência e apresentar resultados médios de acordo com a realidade observada, pelo que poderá concluir-se como adequado para o objetivo em vista. No entanto, futuramente, poderá ser feito um melhor tratamento de dados, de forma a reduzir a incerteza e erros dos mesmos. Para tal, poderá ser utilizada a variável “*timeouts*”, entrando como um fator numa equação de cálculo do valor exato da ocupação.

Após obtidos os registos relativos à ocupação do edifício, desenvolveu-se uma RNA que resultou numa curva de previsão do número de pessoas por carro do parque do *campus*, cujo perfil se revelou semelhante ao de ocupação, com uma média de 78% de correlação e 0,09 de MSE. Estes valores permitem concluir que o número de pessoas por carro determinado pela RNA pode representar de maneira indireta, mas fidedigna, a ocupação real do edifício.

O perfil do número de pessoas por carro e o do consumo elétrico correspondente ao mesmo período de 9 meses foram usados no desenvolvimento de outra RNA, obtendo-se uma previsão de consumo elétrico com um perfil praticamente coincidente com o do consumo real, sendo difícil diferenciá-los, apresentando uma correlação média de 100% e uma MSE diminuta.

Dado que o número de pessoas por carro do parque do *campus* obtido na previsão da primeira RNA pode considerar-se como uma representação fidedigna da ocupação do edifício e fornece uma previsão, pela segunda RNA, sobre o consumo elétrico do edifício, o qual é praticamente coincidente com o consumo real, poderá concluir-se que o número de pessoas por carro do parque de estacionamento do *campus* estudado, poderá ser utilizado como parâmetro de previsão de consumo elétrico a curto-prazo do edifício em estudo do mesmo *campus*. É de salientar que a ocupação não mostrou ter uma influência no consumo elétrico tão grande como o sistema AVAC, não devendo, no entanto, ser desprezada.

Como trabalho futuro seria interessante repetir esta experiência em parques de estacionamento de outros estabelecimentos de ensino universitário, para verificar se as conclusões obtidas neste trabalho podem ser aplicadas e transpostas noutros *campi*. Caso estas conclusões se apliquem, seria também interessante integrar todos estes sistemas de aquisição de dados utilizados neste trabalho numa plataforma capaz de fornecer uma previsão em tempo real, de modo a efetuar ajustes nos sistemas e/ou a sensibilização dos ocupantes, no sentido da eficiência energética.

Referências

- [1] EU, "Directive 2010/31/EU of the Parliament and Council of the European Union of 19 May 2010 on the energy performance of buildings (recast)," *Official Journal of the European Union*, vol. L 153, pp. 13-35, 18 Jun 2010.
- [2] United Nations Environment Programme, Spt 2013. [Online]. Available: <http://www.unep.org/sbci/AboutSBCI/Background.asp>.
- [3] World Business Council For Sustainable Development, "EEB's report on Transforming the Market: Energy Efficiency in Buildings," Jun 2009. [Online]. Available: <http://www.wbcsd.org/transformingthemarketeeb.aspx>.
- [4] Governo da República Portuguesa, "Decreto-Lei n.º 118/2013," *Diário da República, 1ª Série*, vol. 159, pp. 4988-5005, Agosto 2013.
- [5] M.C. Leung, Norman C.F. Tse, L.L. Lai, and T.T. Chow, "The use of occupancy space electrical power demand in building cooling load prediction," *Energy and Buildings*, vol. 55, p. 151–163, Dec 2012.
- [6] R. Pacheco, J. Ordóñez, and G. Martínez, "Energy efficient design of building: A review," *Renewable and Sustainable Energy Reviews*, vol. 16, p. 3559– 3573, Aug 2012.
- [7] A. C. Menezes, A. Cripps, D. Bouchlaghem, and R. Buswell, "Predicted vs. actual energy performance of non-domestic buildings: Using post-occupancy evaluation data to reduce the performance gap," *Applied Energy*, vol. 97, p. 355–364, Sept 2012.
- [8] J. Yang, H. Rivard, and R. Zmeureanu, "Building energy prediction with adaptive artificial neural networks," em *Proceedings of Ninth International IBPSA Conference on Building Simulation*, Montréal, 2005.
- [9] F. Oldewurtel, D. Sturzenegger, and M. Morari, "Importance of occupancy information for building climate control," *Applied Energy*, vol. 101, p. 521–532, Jan 2013.
- [10] V. Fabi, R. V. Andersen, S. P. Corngati, B. W. Olesen, and M. Filippi, "Description of occupant behaviour in building energy simulation: state-of-art and concepts for improvements," em *Proceedings of Building Simulation 2011: 12th Conference of International Building Performance Simulation Association.*, Sydney, 2011.
- [11] C. Martani, D. Lee, P. Robinson, R. Britter, and C. Ratti, "ENERNET: Studying the dynamic relationship between building occupancy and energy consumption," *Energy and Buildings*, vol. 47, p. 584–591, Apr 2012.
- [12] A. Fouquier, S. Robert, F. Suard, L. Stéphan, and A. Jay, "State of the art in building modelling and energy performances," *Renewable and Sustainable Energy Reviews*, vol. 23, p. 272–288, Jul 2013.
- [13] E. A. Feinberg, and D. Genethliou, "Applied Mathematics for Power Systems: Load Forecasting," in *Applied mathematics for restructured electric power systems: optimization, control, and computational intelligence*, New York, Springer, 2005, pp. 269-28.
- [14] A. Badri, Z. Ameli, and A.M. Birjandi, "Application of artificial neural networks and fuzzy logic methods for short term load forecasting," *Energy Procedia*, vol. 14, pp. 1883-1888, 2012.
- [15] A. Kazemi, H. Shakouri, M.B. Menhaj, M.R. Mehregan, and N. Neshat, "A multi-level artificial neural network for residential and commercial energy demand forecast: Iran case study," in *Proceedings of 3rd International Conference on Information and Financial Engineering International*, Shanghai, 2011.
- [16] A. Marvuglia, and A. Messineo, "Using recurrent artificial neural networks to forecast household electricity consumption," *Energy Procedia*, vol. 14, pp. 45-55, 2012.
- [17] P. Lauret, M. David, and D. Calogine, "Nonlinear models for short-time load forecasting," *Energy Procedia*, vol. 14, pp. 1404-1409, 2012.
- [18] M. Krarti, "Energy Audit of Building Systems: An Engineering Approach, CRC Press, Boca Raton, FL, 2000, cited," em *The use of occupancy space electrical power demand in building cooling load prediction*, vol. 55, Energy and Buildings, 2012, p. 151–163.

- [19] M. Hart, and R. de Dear, "Weather sensitivity in household appliance energy end-use," *Energy and Buildings*, vol. 36, p. 161–174, Feb 2004.
- [20] S. Sherwood, "What is Wet Bulb temperature?," 7 Mar 2012. [Online]. Available: <http://www.crc.unsw.edu.au/staff/profiles/sherwood/wetbulb.html>. [Accessed 10 Aug 2013].
- [21] S. Jaber, and S. Ajib, "Evaporative cooling as an efficient system in Mediterranean region," *Applied Thermal Engineering*, vol. 31, p. 2590–2596, October 2011.
- [22] M. Abuku, Hans Janssen, and S. Roels, "Impact of wind-driven rain on historic brick wall buildings in a moderately cold," *Energy and Buildings*, vol. 41, p. 101–110, Jan 2009.
- [23] R. Lindberg, A. Binamu, and M. Teikari, "Five-year data of measured weather, energy consumption, and time-dependent temperature variations within different exterior wall structures," *Energy and Buildings*, vol. 36, p. 495–501, Jun 2004.
- [24] D H.W. Li, and J. C. Lam, "Analysis of solar heat gain factors using sky clearness index," *Energy Conversion and Management*, vol. 42, p. 555±571, Mar 2001.
- [25] K. Wojdyga, "An influence of weather conditions on heat demand in district," *Energy and Buildings*, vol. 40, p. 2009–2014, 2008.
- [26] G. Chicco, and P. Mancarella, "Distributed multi-generation: a comprehensive vie," *Renewable and Sustainable Energy Reviews*, vol. 13, p. 535–551, Apr 2009.
- [27] N. Kandil, R. Wamkeue, M. Saad, and S. Georges, "An efficient approach for shortterm load forecasting," em *Proccedings of 2006 IEEE International Symposium on Industrial Electronics*, Montreal, 2006.
- [28] A. E. Ben-Nakhi, and M. A. Mahmoud, "Cooling load prediction for buildings using general regression neural networks," *Energy Conversion and Management*, vol. 45, p. 2127–2141, Aug 2004.
- [29] T. Catalina, J. Virgone, and E. Blanco, "Development and validation of regression models to predict monthly heating," *Energy and Buildings*, vol. 40, p. 1825–1832, 2008.
- [30] R. Lindberg, M. Korpi and J. Vinha, "Factors affecting energy consumption of buildings," 08 Jun 2008. [Online]. Available: <http://www.nibs.org/?page=best1>. [Accessed 12 Aug 2013].
- [31] J. Kim, and J. Moon, "Impact of insulation on building energy consumption," em *Proceedings of Eleventh International IBPSA Conference on Building Simulation*, Glasgow,, 2009.
- [32] Smart-Accelerate Project, Intelligent Buildings Assessment Methodology, "SMART-ACCELERATE PROJECT, Intelligent Buildings Assessment Methodology," Nov 2004. [Online]. Available: <http://www.ibuilding.gr/training.html>. [Acedido em 10 Aug 2013].
- [33] Instituto para la Diversificación y Ahorro de la Energia, "IDAE," Jul 2007. [Online]. Available: <http://www.idae.es/index.php/id.67/reلمenu.333/mod.pags/mem.detalde>.
- [34] R. Yao, B. Lib, and K. Steemers, "Energy policy and standard for built environment in China," *Renewable Energy*, vol. 30, p. 1973–1988, Oct 2005.
- [35] B. Kermanshahi, and H. Iwamiya, "Up to year 2020 load forecasting using neural nets," *International Journal of Electrical Power and Energy Systems*, vol. 24, pp. 789-797, Nov 2002.
- [36] P. Pai, and W. Hong, "Support vector machines with simulated annealing algorithms in electricity load forecasting," *Energy Conversion and Management*, vol. 46, p. 2669–2688, Oct 2005.
- [37] V. M. Zavala, E. M. Constantinescu, T. Krause, and M. Anitescu, "On-line economic optimization of energy systems using weather," *Journal of Process Control*, vol. 19, p. 1725–1736, Dec 2009.
- [38] D. Robinson, "Some trends and research needs in energy and comfort prediction," em *Proceedings of Windsor Conference on Comfort and Energy Use in Buildings - Getting them Right*, Windsor, 2006.
- [39] A. Al-Mumin, O. Khattab, and G. Sridhar, "Occupants' behavior and activity patterns influencing the energy consumption in the Kuwaiti residences," *Energy and Buildings*, vol. 35, p. 549–559, Jul 2003.
- [40] H. K. Alfares, and M. Nazeeruddin, "Electric load forecasting: literature survey and classification of methods," *International Journal of Systems Science*, vol. 33, pp. 23-34, Nov 2010.
- [41] Q. Mu, Y. Wu, X. Pan, L. Huang, and X. Li, "Short-term load forecasting using improved similar days method," em *Proceedings of 2010 Asia-Pacific Power and Energy Engineering Conference*, Chengdu, 2010.
- [42] R. F. Engle, C. Mustafa, and J. Rice, "Modeling peak electricity demand," *Journal of Forecasting*,

vol. 11, p. 241–251, Apr 1992.

- [43] M. Y. Cho, J.C. Hwang, and C. S. Chen, "Customer short term load forecasting by using ARIMA transfer function model," in *Proceedings of EMPD '95 International Conference on Energy Management and Power Delivery*, Singapura, 1995.
- [44] M. S. S. Rao, S. A. Soman, B. L. Menezes, P. Chawande, P. Dipti, and T. Ghanshyam, "An expert system approach to short-term load forecasting for reliance energy limited, Mumbai," in *Proceedings of IEEE Power India Conference*, Nova Delhi, 2006.
- [45] N. Farah, M. T. Khadir, I. Bouaziz, and H. Kennouche, "Short-term forecasting of Algerian load using fuzzy logic and expert system," in *Proceedings of ICMCS '09 International Conference on Multimedia Computing and Systems*, Quarzazate, 2009.
- [46] D. K. Ranaweera, N. F. Hubeleand, and G. G. Karady, "Fuzzy logic for short term load," *International Journal of Electrical Power & Energy Systems*, vol. 18, pp. 215-222, May 1996.
- [47] S.K Aggarwal, M. Kumar, L.M. Saini, and A. Kumar, "Short-term load forecasting in deregulated electricity markets using fuzzy approach," *Journal of Engineering and Technology*, vol. 1, pp. 24-30, Jan-Jun 2011.
- [48] C. Gershenson, "Carlos Gershenson's Publications," 20 Aug 2003. [Online]. Available: <http://uk.arxiv.org/ftp/cs/papers/0308/0308031.pdf>. [Accessed 10 Aug 2013].
- [49] S. A. Kalogirou, and M. Bojic, "Artificial neural networks for the prediction of the energy consumption of a passive solar building," *Energy*, vol. 25, p. 479–491, May 2000.
- [50] A. Krenker, J. Bešter, and A. Kos, "Introduction to the Artificial Neural Networks," em *Artificial neural networks - methodological advances and biomedical applications*, Rijeka, InTech, 2011, pp. 3-17.
- [51] M. P. Naeini, H. Taremian, and H. B. Hashemi, "Stock market value prediction using neural networks," em *Proceedings of International Conference on Computer Information Systems and Industrial Management Applications*, Krakow, 2010.
- [52] P. Mandal, T. Senjyu, N. Urasaki, and T. Funabashi, "A neural network based several-hour-ahead electric load forecasting using similar days approach," *Electrical Power and Energy Systems*, vol. 28, p. 367–373, Jul 2006.
- [53] M. Paliwal, and U. A. Kumar, "Neural networks and statistical techniques: A review of applications," *Expert Systems with Applications*, vol. 36, pp. 2-17, Jan 2009.
- [54] A. Khosravi, S. Nahavandi, D. Creighton, D. Srinivasan, "Interval type-2 fuzzy logic systems for load forecasting: a comparative study," *IEEE Transactions on Power Systems*, vol. 27, pp. 1274 - 1282, Aug 2012.
- [55] B. Yan, A. M. Malkawi, and Y. K. Yi, "Case study of applying different enegy use modeling methods," in *Proceedings of Building Simulation 2011:12th Conference of IBPSA*, Sydney, 2011.
- [56] R. Behera, B. P. Panigrahi, and B. B. Pati, "A hybrid short term load forecasting model of an Indian grid," *Energy and Power Engineering*, vol. 3, pp. 190-193, May 2011.
- [57] C. Liao, and P. Barooah, "An integrated approach to occupancy modeling and estimation," em *Proceedings of 2010 American Control Conference*, Baltimore, 2010.
- [58] J. A. Davis III, and D. W. Nutter, "Occupancy diversity factors for common university building types," *Energy and Buildings*, vol. 42, p. 1543–1551, Sep 2010.
- [59] T. Ekwevugbe, N.I Brown, and D. Fan, "A design model for building occupancy," em *Proceedings of 6th IEEE International Conference on Digital Ecosystems Technologies*, Campione d'Italia, 2012.
- [60] J. Hutchins, A. Ihler, and P. Smyth, "Modeling count data from multiple sensors: a building occupancy model," in *2nd IEEE International Workshop on Computational Advances in MultiSensor Adaptive Processing*, St. Thomas, 2007.
- [61] Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa, 2013. [Online]. Available: <http://www.fct.unl.pt/faculdade/planta-do-campus>.
- [62] L. Mendelsohn, "MATLAB Neural Network Toolbox," 2013. [Online]. Available: <http://www.tradertech.com/neural-networks/matlab-neural>.
- [63] P.J.B. Claricoats and E. V. Jull, Propagation of Radiowaves, L. Barclay, Ed., Milton Keynes, 2003.
- [64] O. Torres-Reyna, "Linear Regression," Aug 2013. [Online]. Available: <http://dss.princeton.edu/training/Regression101.pdf>.

